



UNIVERSIDAD DE CÓRDOBA

MODELOS ECONOMETRÍCOS PARA LA PREDICCIÓN DE CALIFICACIONES DE RIESGO FINANCIERO

ECONOMETRIC MODELS FOR FORECASTING FINANCIAL RATINGS

TESIS DOCTORAL

Lorena Caridad y López del Río

Directores:

José M. Caridad y Ocerin

Julia M. Núñez Tabales

2020

Programa de doctorado: Ciencias Jurídicas y Sociales

Depósito: 15 de abril de 2020

TITULO: *Modelos econométricos para la predicción de calificaciones de riesgo financiero*

AUTOR: *Lorena Caridad y López del Río*

© Edita: UCOPress. 2020
Campus de Rabanales
Ctra. Nacional IV, Km. 396 A
14071 Córdoba

<https://www.uco.es/ucopress/index.php/es/>
ucopress@uco.es

AGRADECIMIENTOS

A mis directores y profesores

José M. Caridad y Ocerin y Julia M. Núñez Tabales,
por su orientación y ayuda, a Rosy, Daniel, Carlos y Carla.

A los compañeros del Departamento, por su apoyo



TÍTULO DE LA TESIS: MODELOS ECONOMETRICOS PARA LA PREDICCIÓN DE CALIFICACIONES DE RIESGO FINANCIERO

DOCTORANDA: Lorena Caridad y López del Río

INFORME RAZONADO DEL/DE LOS DIRECTOR/ES DE LA TESIS

(se hará mención a la evolución y desarrollo de la tesis, así como a trabajos y publicaciones derivados de la misma).

El trabajo presentado por la doctoranda ha concluido satisfactoriamente. Ha originado varias publicaciones en revistas indexadas y están en fase de revisión otras con los últimos resultados. También se han derivado otras publicaciones a raíz de sus estancias en la Facultad de CC EE de la universidad VSB en la República Checa, y está en evaluación otra con profesores de la misma.

En el trabajo de tesis se analizan dos cuestiones importantes en el ámbito de la evaluación del riesgo financiero por parte de las agencias de acreditación. La primera es la modelización de las calificaciones crediticias a largo plazo correspondientes a empresas de diversos sectores en función de los estados contables de las citadas empresas, utilizando diversos métodos estadísticos y basados en técnicas de inteligencia artificial. La segunda es la valoración del fenómeno de inflación de puntuaciones crediticias por parte de unas agencias en relación a otras. Además de una recopilación de las técnicas empleadas de evaluación del riesgo.

En la evolución y desarrollo de la tesis se inició con una muestra aleatoria de más de mil empresas correspondientes a los años 2010-2014, seguida de otra muestra de similar tamaño en el periodo 2014-2018, año este último para el que están disponibles los datos del ejercicio contable. La fuente de estos datos ha consistido en la base de datos mayor existente en el mundo de Bloomberg L.P., y gracias al tamaño muestral utilizado se ha podido elaborar modelos de predicción para los veinte niveles de puntuaciones crediticia proporcionados por S&P's y Moody's, las dos mayores agencias existentes.

Los artículos más relevantes publicados en el desarrollo de este trabajo han sido los siguientes: Rating de empresas a partir de datos financieros, Espacios, 2019, 1, 1-14, Scopus Q3; The interaction between governance, social responsibility, and territorial attractiveness: an application of the structural equation modelling approach, Investment Management & Financial Innovations, 2018, 15, 4, 239-257, Scopus Q3; Corporate rating forecasting using AI techniques, Investment Management & Financial Innovations, 2019, 6, 2, 295-312, Scopus Q3; y la presentación del artículo al congreso SMSIS 2019, Return and volatility spillover effects in Western European Stock markets, publicado en el libro; además del artículo Structural models in CSR, Sustainability, 2019, 11, 18, 1-11, Scopus Q2, JCR. Está en evaluación el artículo Do Moody's and S&P Firms ratings differ? a la revista Economics and Sociology (Scopus Q1 y JCR).

Por todo ello, se autoriza la presentación de la tesis doctoral.

Córdoba, 2 de abril de 2020

LOS DIRECTORES

Fdo.: José M. Caridad y Ocerin

Fdo.: Julia M. Núñez Tabales

Summary

Credit Rating Agencies (CRA) provide ordinal assessments associated with the ability of companies, governments, institutions or financial assets, to meet debt obligations on time. These ratings are generated by CRAs as an 'objective' information about the financial health of their customers (although, in some cases, the CRAs provide ratings for third parties), bonds emissions, companies, institutions, and some other agents or financial products. This information is based on two components: the first is estimated from financial and economic sources, usually public, and the second on so called 'qualitative' data, which is part of the proprietary know-how of the agencies.

But, how an independent investor or institution could evaluate the financial health of a company or a new issue? How can it be done without having to incur in the costs of arranging a contract for this purpose with a CRA? Some statistical methods have been employed with this aim, but as the emergency of Artificial Intelligence (AI) tools are becoming widespread, it is possible to model the rating of a company using public data.

In fact, this is possible using public information, available to investors and to financial institutions. The answer to these questions lies in using statistical multivariate methods and AI models to estimate ratings of companies based on information available about their financial and economic data. Most of the literature about financial rating forecasting focuses on bond-rating prediction, and not in company's ratings.

The specification of econometric models to forecast the credit rating of a company involves using exogenous financial variables that produce a causal effect on their creditworthiness, and on their capacity to fulfill their future obligations. Public data are available for most of the companies that are traded on financial markets. In Bloomberg's database, this information and the ratings obtained from the main CRAs, are available.

Long-term rates are divided in two main categories: investment and non-investment grades using a letter scale. Investment grades starts (in Moody's scale) at 'Aaa', which is related to the highest credit quality, and, consequently, the lowest expectation of default risk; they reflect an exceptionally strong capacity to fulfill their financial commitments, and they are not future events that can alter this situation; the 'Aa' rating is linked to very high credit quality, and low default risk. Following it is the 'A' level, associated to high credit quality and low possibility of default, but can be influenced by changes in the business environment. Finally, the 'Baa' level is associated with medium risk. The junk grade level starts at 'Ba' and 'B', which is associated to high risk of default, the 'Caa' and 'Ca' to highest risks, and finally, level 'C' is associated to firms in default, that is, with the presence of credit events of failure to pay interest or principal of a loan or security when due, and the debtor is unable to meet the legal obligation to debt repayment. The information provided by these values is ordinal, and not directly associated with probabilities of default. Moreover, more troubling is that the risk increase linked to a notch downgrade is not constant along the scale; more still, these

variations are not comparable between them, and still less, they cannot be quantified. Some Multivariate Analysis methods used to estimate rates produce less accurate classifications; for example, Discriminant Analysis reaches only 20.7% of correct forecasted ratings, but only 16.7% when using jackknife methods to exclude one case at the time, as trial set. Multivariate logit (or similar models) are in the same range. While non-linear methods, such as Artificial Neural Networks, provide much better results, if a sufficiently large sample is used to train the model. The first main objective proposed is to elaborate models that can reproduce S&P's and Moody's long-term ratings using publicly available data. The second main objective is to analyze the phenomenon called 'rate inflation', that is, the attribution of a certain level of rating above the 'objective level' which would be generated by an impartial observer. As Moody's ratings tend to be lower than those obtained by S&P's, these differences are considered as an evidence of rating inflation. This has been studied, also, in different economic sectors. Data employed come from two random samples of over one thousand companies each, for the years 2010 to 2018, and from thirteen economic sectors.

Keywords: firm ratings, forecasting, conflicts of interest, rating inflation, credit rating agencies

JEL C15 C18 C53 G24 G17 G32 F65 D53

ÍNDICE

1. INTRODUCCIÓN

1.1. Introducción y antecedentes	3
1.2. Objetivos	9
1.3. Justificación	12

CAPÍTULO 2. EL RIESGO Y SU CONTROL

2.1. Riesgo de crédito	18
2.2. Cuantificación del riesgo	30
2.3. Modelos para riesgos individuales	35
2.4. Modelos para riesgos relacionados.....	40
2.5. Los estados contables y el riesgo.....	48

CAPÍTULO 3. LAS AGENCIAS DE CALIFICACIÓN

3.1. Introducción.....	63
3.2. Evolución histórica	72
3.3. Puntuaciones elaboradas por las agencias	76
3.4. Normativa regulatoria.....	81

CAPÍTULO 4. MÉTODOS ESTADÍSTICOS DE CLASIFICACIÓN PARA RATINGS

4.1. Introducción.....	101
4.2. Métodos estadísticos de clasificación.....	110
4.3. Métodos basados en técnicas de Inteligencia Artificial.....	136

CAPÍTULO 5. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

5.1. Material estadístico disponible	149
5.2. Distribución de los <i>ratings</i>	155
5.3. Análisis de variables explicativas y ratios	168
5.4. Modelos basados en técnicas multivariantes	188
5.5. Modelos basados en RNA	199
5.6. Resumen de resultados	226

CAPÍTULO 6. COMPARACIÓN DE PUNTUACIONES DE DIVERSAS AGENCIAS

6.1. Problemática en la elaboración de puntuaciones de empresas	233
6.2. Índices de desplazamiento de las valoraciones de agencias	240
6.3. Comparación de puntuaciones otorgadas por S&P's y Moody's.....	247
6.4. Comparaciones sectoriales	261
6.5. Resumen de comparaciones.....	315

CAPÍTULO 7. CONCLUSIONES

7.1. Conclusions	325
7.2. Future developments	331

REFERENCIAS.....	333
-------------------------	------------

I. INTRODUCCIÓN

1.1. Introducción y antecedentes

1.2. Objetivos

1.3. Justificación

I INTRODUCCIÓN

I INTRODUCCIÓN

1.1. Introducción y antecedentes

El dinero o efectivo en manos de una persona física o jurídica se puede emplear en tres fines básicos: consumo (gasto en bienes para satisfacer necesidades), inversión (empleo en adquirir otros bienes económicos o financieros, para obtener un rendimiento), y atesoramiento. El dinero es pues un activo sin riesgo, y, otros activos emitidos por el Estado, como la Deuda Pública, también se consideran sin riesgo, aunque existen casos recientes como Argentina o Grecia, en que no ha sido así.

Los enfoques tradicionales del desarrollo de las teorías económicas, con respecto a los mercados financieros se basaban en que el dinero era la única magnitud que se debería tener en cuenta. Las teorías clásicas no atribuían gran importancia al efecto real sobre el desarrollo de los mercados financieros. Keynes, desde antes de la segunda guerra mundial, plantea la doble finalidad de los mercados: las relacionadas con la financiación de las empresas, y los sistemas de ahorro en carteras de inversión.

Los ingresos de una empresa o de una familia no siempre coinciden con los gastos. Si estos son inferiores, la solución habitual es recurrir al crédito. El papel del sistema financiero es proporcionar los fondos precisos cuando son necesarios. Existen agentes económicos que tienen superávit de liquidez y están dispuestos a conceder crédito, y otros, pagan un interés para usarlo. La esencia pues del sistema es la planificación temporal de los flujos de fondos.

Lógicamente, la inflación es habitual en los sistemas monetarios; quien renuncia a usar sus propios fondos en un instante, para serles reintegrados posteriormente, debe percibir un interés que le compense por la pérdida de poder adquisitivo; además, el proveedor de fondos renuncia a hacer uso de éstos, al concederlos en forma de crédito o préstamo a otra persona, que se los debe reintegrar en el futuro; el interés remunera esta cesión así como el riesgo de no devolución y la depreciación monetaria.

I INTRODUCCIÓN

El tiempo es un factor fundamental a la hora de valorar un capital, pues es obvio que no es lo mismo disponer de una cantidad, por ejemplo, un millón de euros, en este momento, que en un instante futuro. El principio de preferencia por la liquidez muestra que es preferible la disposición de un capital en el instante actual que en un instante posterior. Así pues, al hacer referencia a una cantidad monetaria, C , es preciso indicar el instante, t , en la que está disponible, es decir, su vencimiento. Un capital financiero está definido mediante estas dos magnitudes (C, t) : el nominal C , o importe monetario, y el instante t en que es devengado o efectivo.

La actividad financiera de una empresa o de una institución se centra en actividades de gestión, en decisiones de inversión (es decir, la selección de los activos necesarios para desempeñar su función) y en la obtención de los recursos mediante las decisiones de financiación adecuadas, emitiendo activos financieros. Esto supone el manejo y valoración de capitales financieros, el intercambio de éstos y la realización de operaciones financieras. A veces, las empresas realizan directamente estas operaciones de compra y venta de capitales financieros, pero en el mercado existen otros agentes que compran y venden activos financieros: no solo los inversores y los demandantes de fondos; los intermediarios pueden adquirir activos financieros y facilitar las transacciones. Muchas de las operaciones usuales están integradas en mercados regulados, con entes supervisores, para darle mayor seguridad a éstas. Otras se realizan en mercados no regulados.

Una operación financiera consiste en el intercambio de capitales (financieros, es decir, que además del nominal, llevan asociadas las correspondientes fechas de devengo) en instantes distintos del tiempo, y de acuerdo con una ley financiera asociada a la operación.

Las operaciones financieras clásicas son las concesiones de préstamos o de créditos, la emisión de bonos y obligaciones, el descuento comercial, las operaciones a plazo o de cuentas de diversos tipos. Las leyes financieras usuales se consideran de capitalización y de descuento, y permiten trasladar en el tiempo capitales financieros en otros equivalentes (de acuerdo a dicha ley). En el momento de su contratación se verifica un postulado de equivalencia financiera entre la prestación y la contraprestación de la

I INTRODUCCIÓN

operación. Implícitamente se presume que ambas partes disponen de toda la información relevante relacionada con la operación. Pero en la práctica no es así: en muchas ocasiones una parte dispone de más información que la otra, es decir, se produce una asimetría en la información. En los últimos años se han dado casos muy conocidos en España, que han dado origen a numerosas sentencias judiciales, que incluso llegan a poner en entredicho otro principio no menos importante: el de la seguridad jurídica.

Pero en las últimas tres décadas se han ido creando nuevos instrumentos financieros; algunos sin gran complejidad, pero otros son mucho más elaborados, con lo cual la valoración de los capitales financieros asociados es algo difícil de conseguir. La asimetría de la información cobra todavía mucho más importancia en los mercados financieros.

Todo ello incrementa la incertidumbre en los mercados, y esta incertidumbre tiene una componente de riesgo añadida.

Pero incluso en una operación clásica como una emisión de obligaciones (sin entrar en referenciar distintos tipos de títulos ni sus condiciones), una parte proporciona un capital con la promesa de recuperarlo con sus respectivos intereses en instantes posteriores. Cabe la posibilidad que el deudor no cumpla con sus obligaciones crediticias y resulte fallida la devolución o algún pago asociado a este activo financiero.

El riesgo es parte fundamental de cualquier operación financiera. Y en los últimos años se han desarrollado numerosas técnicas matemáticas para valorar el riesgo y determinar magnitudes asociadas a la posibilidad de fallido.

Todos estos controles se refieren generalmente a las emisiones de activos financieros (bonos, obligaciones, productos derivados, titulizaciones y otros productos estructurados con garantías asociadas - que también incorporan una componente de

I INTRODUCCIÓN

riesgo de incumplimiento -, o incluso emisiones de acciones). Pero también se producen riesgos asociados a empresas, países, o instituciones.

Cuando una empresa va a efectuar, en un mercado primario, una emisión de activos financieros, como son las obligaciones de un empréstito, el regulador (la Comisión Nacional del Mercado de Valores) le exige una evaluación externa del riesgo de impago o riesgo de crédito en la devolución de los capitales que recibe. Una agencia de acreditación (*Credit Rating Agency*, CRA), como son Standard & Poor's (S&P's) o Moody's, o Fitch, realizan la evaluación de esta emisión, y emiten una puntuación o *rating* crediticio. Su misión (Minescu, 2010) es informar a los posibles inversores de la calidad crediticia de esta emisión, es decir, compensar la asimetría de información que se da en esta operación financiera: la empresa conoce perfectamente su situación económica y financiera y tiene unas determinadas expectativas de negocio; sin embargo, el emisor se tiene que conformar con los estados contables emitidos anualmente por la empresa, y que proporcionan una información parcial del pasado.

De igual forma que la agencia califica una emisión de activos, también puede, y de hecho lo hace, emitir calificaciones de empresas (Ong, 2002). Estas calificaciones tienen como fin informar a los posibles inversores sobre la fiabilidad crediticia de la empresa, tanto a corto como a largo plazo. Y la metodología utilizada es solo parcial, como indican Ligeti y Szörfi (2016).

El sistema de control de la fiabilidad crediticia de las empresas que acuden a los mercados primarios depende, en gran medida, de las evaluaciones que realizan las agencias de calificación o *rating*. Éstas proporcionan estimaciones de la capacidad de cumplimiento de las obligaciones crediticias y de la salud financiera de empresas e instituciones sobre el cumplimiento puntual de sus compromisos de pago. Sobre su fiabilidad existen numerosos trabajos, y controversias, como el de Becker y Milbourn (2009), y en los que intervienen directamente los reguladores, como la Australian Securities & Investments Commission (2019), al igual que los encargados en los

I INTRODUCCIÓN

Estados Unidos de América y en distintos países europeos (European Commission, 2015).

La metodología seguida por las grandes compañías de *rating* no es completamente pública; en parte es conocida, pero también las agencias se reservan información relevante que solo hacen pública de forma parcial y, en gran medida, imprecisa. Todas ellas afirman usar dos tipos de fuentes: la primera, datos sobre las compañías o sobre las emisiones -que son públicos o pueden obtenerse sin gran dificultad-, pero también usan otro bloque de información que la califican de 'cualitativa' y que es desconocida. Por ello, un evaluador de una emisión de activos o de una empresa no dispone de la información necesaria para poder reproducir el *rating* o calificación asignado a ésta. Fitch (2018) informa sobre los parámetros y magnitudes públicas que usa en sus evaluaciones, en la parte cuantitativa.

La iniciativa de generación de una calificación, generalmente, parte de la propia compañía emisora interesada; algunos reguladores incluso la exigen, por ejemplo, para la emisión de obligaciones. Pero también puede ser publicada por la agencia de *rating*, sin que haya una solicitud previa. En la primera alternativa, la compañía evaluada es cliente de la agencia de calificación, pudiéndose generar los correspondientes conflictos de intereses. De hecho, algunas agencias tienden a proporcionar calificaciones de mayor nivel que otras para las mismas instituciones o productos.

Las agencias de calificación no se comprometen en sus evaluaciones crediticias. En los contratos con las compañías evaluadas o con instituciones, incluso en las obtenidas sin encargo previo, advierten que las calificaciones o *ratings* son solo informativas, que no son recomendaciones de inversión y que dependen de la información de la que disponen, por lo que no se dispone de información sobre su precisión y fiabilidad (Viegas *et al*, 2014). Es decir, las plantean como opiniones, como las que puede emitir un periódico que informa a sus lectores de noticias, sin asumir responsabilidad sobre las mismas (Langhor y Langhor, 2011). Alguna agencia de calificación está constituida como una empresa en el sector de la prensa especializada.

I INTRODUCCIÓN

En resumen, las agencias de *rating* publican sus informes y calificaciones sin asumir responsabilidades sobre las consecuencias que pudieran suponer para inversores o acreedores. A pesar de ellos, casi todos los reguladores y fondos de inversión, requieren las calificaciones de estas agencias de calificación para operaciones de emisión o para seleccionar los activos de sus carteras.

Pero, ¿es posible para, por ejemplo, un inversor realizar evaluaciones de las calificaciones emitidas sobre empresas que acuden a los mercados en busca de fondos?, o, ¿la única alternativa es usar los *ratings* de las agencias? La respuesta es solo parcial, pues, en teoría, las agencias utilizan toda la información disponible, incluso la que no es pública; y, además, las calificaciones pueden variar a lo largo del tiempo. Es decir, a corto plazo, no es fácil predecir las calificaciones.

Pero, en muchas decisiones de inversión sectorial, se emplean calificaciones de empresas a medio plazo y estas sí son reproducibles de forma independiente (como se verá más adelante) a partir de información pública: básicamente, los estados contables y los ratios económicos financieros derivados de éstos. Además, la posibilidad de acceder a grandes bases de datos y el uso de técnicas de inteligencia artificial, permite estimar o reproducir los *ratings* publicados y, a partir de los modelos estimados, predecir las calificaciones de otras empresas para las que no existe una calificación explícita.

Algunos autores han estudiado la estimación de *ratings* de algunas compañías. Gogas *et al.* (2014) así como Novotna (2012), Lee y Lin (2014) y Ptak-Chmielewska (2016) utilizan diversos métodos estadísticos para predecir el *rating* de entidades bancarias y comparar la eficiencia de los distintos métodos, como también desarrollan Gangolf *et al.* (2016) al comparar métodos de cuantificación de las calificaciones crediticias, incluyendo técnicas de inteligencia artificial. Kee (2005) utiliza información pública para predecir las puntuaciones. Saha y Waheed (2017) reproducen las calificaciones de emisiones de renta fija mediante el uso de redes neuronales. Otros autores, como Karminsky y Khromova (2016) utilizan modelos con variable endógena no numérica,

I INTRODUCCIÓN

con las categorías asociadas a las calificaciones. Actualmente, los nuevos desarrollos en la predicción de *ratings* se orientan hacia el uso de herramientas de inteligencia artificial en la predicción, incluyendo las denominadas *Support Vector Machines*, (Nehrebecka, 2018) o los árboles aleatorios (Tzu-Tsung y Shang-Jung, 2019).

1.2. Objetivos

La obtención de *ratings* para empresas es un proceso cuanto menos caro, sin duda no transparente, y para los cuales, no es posible contrastar su precisión y fiabilidad. La mayor parte de las calificaciones se estiman para emisiones de productos financieros y, en menor medida, para las propias empresas, que es el campo que se aborda en este trabajo. Sin embargo, existe una gran cantidad de información financiera que si es accesible, y que nos informa de forma exhaustiva sobre la situación de los mercados y sus perspectivas. Esta información es sobre-abundante, y no es conocida que parte de ésta es usada por las agencias de calificación crediticia en sus evaluaciones. Una conjetura que, sin duda, no deja de estar fundamentada, es que la información económica y financiera que publican las empresas anualmente, juega un papel fundamental en la evaluación de una compañía o de una emisión de activos financieros. Pero, ¿es esta suficiente para evaluar a una corporación, como se propone en los textos de finanzas en la empresa?, o ¿existen otros factores fundamentales a tener en cuenta?

En principio partimos de la base que los estados contables anuales (balance de situación, cuenta de resultados y estado de flujos de caja, completados con la memoria anual) pueden ser suficientes para evaluar las perspectivas de una compañía, y estimar su *rating* a largo plazo. La palabra 'suficiencia' cabe también interpretarla en el sentido de la Inferencia Estadística, sobre la no pérdida de información en los procesos de reducción de dimensión. Los procesos de elaboración de un *rating* no dejan de ser una metodología de reducción de dimensión de los datos empresariales, de los mercados, de los entornos geográficos y sus condiciones, a un único valor: una puntuación ordinal en la que aspiramos a resumir la información sobre la salud financiera y perspectivas de una empresa. No cabe duda que un *rating* no se puede considerar una transformación suficiente de todos estos factores causales, aunque en la práctica así se utilice.

I INTRODUCCIÓN

Es evidente que otros factores pueden hacer cambiar estas previsiones; máxime, encontrándonos a mediados de marzo de 2020 en el que un hecho externo como una epidemia que azota España e Italia aparentemente con más virulencia que a sus vecinos, ha hundido las cotizaciones, y posiblemente afectará a los *ratings* de más de una empresa y a su salud crediticia. Nada nuevo ni inesperado, aunque si improbable - pero que está ocurriendo en estos momentos -, para cualquier lector de 'The Black Swan' de Nassim N.Taleb (2010).

Los objetivos básicos acometidos se basan en la premisa que los mercados tienen períodos de estabilidad, y que en esos momentos cabe realizar medidas sobre sus agentes, con perspectivas de estabilidad. Las cuestiones concretas abordadas son:

1. Estimar los *ratings* a largo plazo de empresas mediante modelos estadísticos, y contrastar que es posible reproducir las calificaciones a largo plazo otorgadas a empresas de distintos sectores económicos, utilizando datos públicos, es decir, de los estados contables de las empresas, y evaluar las calificaciones obtenidas por las agencias S&P's y Moody's.

2. Construir una metodología que pueda ser aplicada para elaborar los *ratings* de empresas, sin necesidad de incurrir en los gastos de contratar a alguna de las grandes agencias, y poder aplicarlo a empresas de distintos sectores económicos, utilizando diversos métodos estadísticos, discriminando entre ellos en función de su capacidad predictiva, y comparar distintas técnicas estadísticas en este cometido.

3. Analizar el fenómeno de la inflación de *ratings*, fenómeno que se considera que se puede estar produciendo, generando puntuaciones superiores a las que realmente les podrían corresponder, para muchas empresas, deformando la motivación de participación de las grandes agencias en los mercados financieros, que se resumen en proporcionar una información fiable y objetiva para paliar la asimetría de la información

I INTRODUCCIÓN

existente entre los emisores de activos y los inversores, y dificultando la comparación de la calidad crediticia entre empresas competidoras.

4. Investigar la situación relativa en los procesos de asignación de *ratings* entre las dos mayores agencias (S&P's y Moody's), estudiando las diferencias existentes, y su posible relación con el citado fenómeno de la inflación de *ratings*.

5. Particularizar los dos puntos anteriores a distintos sectores empresariales, analizando el comportamiento diferenciado de las dos agencias citadas, para detectar comportamientos que pueden ser sistemáticos, en algunos casos, lo que afecta a la fiabilidad que pueden tener los *ratings*.

La información disponible en el proceso de modelización y comparación de la asignación de *ratings* se basa en una base de datos pública, que engloba la mayor parte de las empresas a nivel global. En esa base de datos se ha realizado un doble muestreo, seleccionando aleatoriamente un número elevado de empresas. El primer grupo abarca el período 2010-2014, y el segundo el período 2014-2018 (este es el último ejercicio disponible). En ambas bases de datos se han extraído los estados contables y las calificaciones crediticias otorgadas por las dos mayores agencias; y a partir de estos datos se han obtenido una serie de ratios económico-financieros que se consideraba podían ayudar a determinar el riesgo crediticio a largo plazo de cada empresa. Y con esta información se han elaborado distintos modelos de predicción, y se ha investigado el fenómeno de la inflación de calificaciones, y el distinto comportamiento de las agencias según el sector económico.

Existen varias bases de datos estadísticos de tipo económico-financiero, como las proporcionadas por Bloomberg, Bankscope u otras instituciones. Aquí se ha utilizado la primera de estas bases, a pesar de su elevado coste de acceso.

I INTRODUCCIÓN

1.3. Justificación

Los dos principales problemas prácticos que tiene el sistema de calificación crediticia de empresas son

- el coste de obtención de los *ratings*, que requieren contratar a una agencia evaluadora y realizar un estudio amplio sobre la salud crediticia de la empresa.

y

- la incertidumbre sobre la objetividad de los mismos, pues son las propias empresas emisoras las que contratan a las agencias para que éstas emitan las calificaciones sobre la fiabilidad financiera de las empresas en el cumplimiento de sus obligaciones. Es decir, el evaluador es pagado por el evaluado.

Además, un inversor no tiene acceso al proceso de obtención de los *ratings*, por lo cual no tiene forma de conocer si la calificación que le ha obtenido una empresa emisora es realmente fiable o esta sobre o infravalorada.

Estas cuestiones se abordan en estas páginas, proponiendo resultados que responden a las cuestiones planteadas, mejorando los resultados previos que se encuentran en la literatura.

También, se analiza si el contratar a una agencia o a otra puede influir o no en la calificación final obtenida, es decir se existe o no inflación en los *ratings* asignados.

En el capítulo segundo se hace un recorrido por diversas cuestiones de gestión del riesgo, y como se ha complicado el proceso en los últimos años al surgir numerosos instrumentos financieros cuya valoración requiere abordar un proceso matemático y numérico complejo. Los estados financieros de una empresa, y una serie de ratios tanto económicos como financieros se comentan, como base en capítulos posteriores de los procesos de modelización.

I INTRODUCCIÓN

En el capítulo tercero se describe la problemática asociada a la evaluación de empresas y de emisiones de activos por las empresas de calificación. La metodología que emplean, en la parte que es conocida, y la evolución histórica de estas agencias, de ser, en su período inicial, realmente consultoras financiadas por los inversores para paliar la asimetría de la información existente entre los gestores de una compañía, que, lógicamente disponen de todos los datos relativos a la marcha de la empresa, sus perspectivas, la situación de sus clientes y mercados, y la calidad de la gestión, frente a un inversor externo que generalmente solo dispone de los estados contables públicos; esta evolución ha concluido en un modelo financiado por los propios emisores de activos financieros, o por las propias empresas que necesitan tener una evaluación

En el capítulo cuarto se presentan los métodos

estadísticos que se utilizan en la modelización de los *ratings*, y en el capítulo quinto se aplican a dos amplios conjuntos de datos de empresas obtenidas de las bases de datos de Bloomberg. Los modelos de variable endógena no numérica, como los logísticos, que se emplean para predecir si una calificación están en el grado de inversión o en el especulativo. Los modelos de análisis discriminante se usan para predecir el *rating* a largo plazo de una empresa a partir de variables causales tomadas de los estados contables unidos a una serie de ratios obtenidos a partir de éstos. En estos modelos de análisis discriminante se parte de información muestral de todas estas variables causales para un conjunto (en nuestro caso, dos muestras asociadas a distintos períodos de tiempo) de empresas para las que se dispone de las variables obtenidas de los estados contables públicos, de los ratios obtenidos a partir del balance, de la cuenta de resultados y del estado de flujos de caja, y de la información de la puntuación atribuida por las agencias S&P's y Moody's. Esta variable de clasificación es la que se trata de predecir utilizando funciones discriminante. Se consideran las veinte clases asociadas a los distintos *ratings* de dos formas: agregadas en unos subconjuntos de clasificación que engloban varios *ratings* contiguos, y, por otra parte, las veinte clases reales para realizar una predicción del *rating* exacto. Otra técnica de clasificación empleada es la basada en redes neuronales artificiales. Una red neuronal puede considerarse como parecida a un modelo de regresión no lineal, uni o multivariante, en el que existen unas variables de entrada, que pueden ser exógenas, aunque, en el caso de modelos dinámicos, cabe introducir variables endógenas retardadas. Las variables de

I INTRODUCCIÓN

salida o endógenas, están conectadas a través de un diagrama causal a las de entrada; este grafo define la topología de la red. En las interconexiones aparecen una serie de variables no observables o neuronas, que se ordenan en una o varias capas, a través de las cuales se transmite la información de entrada hasta las variables de salida. Cada neurona procesa la información que recibe de las variables de la capa anterior a la que está conectada, la procesa, y, la transmite, en su caso, filtrada a través de una función de activación. En cada interconexión causal, es necesario estimar varios parámetros, con el objetivo que las estimaciones de las variables endógenas reproduzcan lo más fielmente posible a éstas. Un método de estimación usual es el algoritmo de propagación hacia atrás, en la que las estimaciones de las últimas capas se van alterando para disminuir los residuos del modelo, hasta llegar a la capa de entrada y siguiendo un proceso iterativo.

Las redes neuronales artificiales (RNA) se utilizan en numerosos problemas de predicción. Tsai *et al.* (2008), Frank (2018) y Zhao *et al.* (2015) han empleado estas técnicas en predicción de *ratings* agregados. La estimación de las calificaciones otorgadas a emisiones de activos financieros puede estimarse indirectamente con este tipo de modelos, aunque, en este caso, se emplean para obtener el *rating* de compañías. García-Moreno *et al.* (2015) analizan la eficiencia de los mercados mediante métodos estadísticos. En la red empleada, se utiliza una variable endógena, el *rating* empleado por S&P's, y como variables de entrada, una serie de ratios financieros obtenidos a partir de los estados contables de un conjunto amplio de compañías contenidas en la base de datos Bloomberg, y correspondientes a un intervalo temporal de cinco años anteriores al período en el que se realiza la predicción. Esta información es pública, por lo que el objetivo último es poder predecir la calificación crediticia de compañías de distintos sectores sin tener que recurrir a las agencias de *rating*.

Es evidente que, al no utilizar información cualitativa (lo derivado de sucesos anormales que se puedan producir en el entorno económico-financiero de cada sector), la predicción se efectúa con un horizonte temporal no inmediato.

I INTRODUCCIÓN

Los resultados obtenidos para la predicción mejoran los encontrados en la literatura académica, son extrapolables a otras empresas distintas a las utilizadas, y no requieren incurrir en costes elevados para replicarlas y aplicarlas en la evaluación de las puntuaciones de las agencias de calificación así como en la investigación del fenómeno de la inflación de *ratings*.

I INTRODUCCIÓN

II. EL RIESGO Y SU CONTROL

2.1. Riesgo de crédito

2.2. Cuantificación del riesgo

2.3. Modelos para riesgos individuales

2.4. Modelos para riesgos relacionados

2.5. Los estados contables y el riesgo

2.1. Riesgo de crédito

El riesgo está asociado a la ocurrencia de sucesos, en parte aleatorios, que pueden originar una pérdida económica. Aunque hay diferentes opiniones sobre el origen de la palabra, basta señalar que en latín, ‘resecare’ está asociado a varios conceptos como ‘dividir’, ‘cortar’, ‘peligro’,..., es decir, la posibilidad de soportar un suceso negativo o daño; en el ámbito económico y en el financiero, este daño se refiere a un quebranto o pérdida de algún bien económico, es decir, que origine una minusvalía financiera o un siniestro (en el ámbito actuarial). Además hay que considerar que la idea de riesgo no está asociada a sucesos puramente determinista, sino que, implícitamente se une a la ocurrencia de un suceso o evento que está vinculado a una distribución de probabilidad.

En el ámbito empresarial, la gestión supone el tomar decisiones en ambientes de incertidumbre, lo que origina la aparición del riesgo respecto de los resultados, que pueden originar ganancias o pérdidas, en función de numerosos factores, muchos de los cuales no son controlables por el decisor.

Si se producen pérdidas, los factores causales que las condicionan pueden ser de distinta naturaleza, lo que da origen a distintas variedades de riesgo. Así se habla de riesgo de crédito, riesgo operacional, riesgo de mercado, riesgo financiero, riesgo administrativo, riesgo reputacional, riesgo de contraparte, etc.

Históricamente los riesgos a los que estaba sometida una empresa eran los dos clásicos:

- riesgo de crédito, considerado el más importante, y, originado por la posibilidad de resultar fallidas operaciones activas, y

II. EL RIESGO Y SU CONTROL

- riesgo de mercado cuya causa está asociada a cambios en el entorno, como los tipos de interés o de cambio, o las variaciones de los activos financieros

Los demás riesgos estaban comprendidos bajo un epígrafe genérico de 'otros riesgos', entre éstos, el riesgo operativo u operacional.

Este riesgo operacional lo han soportado los bancos desde su inicio, y la ocurrencia de quebrantos debido a éste, son muy frecuentes, en función de la eficiencia de la operatoria de todas las actividades bancarias. Sin embargo, los riesgos operativos no han tenido importancia hasta hace unos años, ya que, en el pasado, han originado frecuentes pérdidas, pero, generalmente de magnitud reducida. Además, estas pérdidas se han producido de forma sistemática, y, por lo tanto, se podían predecir, y, en gran medida, prevenir. Por ejemplo, los descuadres en la operatoria contable, fallos tecnológicos, fraudes en tarjetas de crédito, incorrecciones fiscales, ataques a oficinas o cajeros automáticos, etc.

El riesgo operacional dependía del tamaño del banco, de su volumen de operaciones y de su dispersión geográfica. Complementariamente, la regulación bancaria limitaba las posibilidades de incurrir en riesgos operacionales importantes. Por lo tanto, las pérdidas ocasionadas han sido absorbidas por las entidades sin dificultades.



Gráfico 2.1 Tipos de riesgo

Fuente: Lara (2006)

Esto era así hasta hace unos veinte años. Sin embargo la evolución de los sistemas financieros en las dos últimas décadas ha hecho que cambie el panorama de forma radical. La globalización de los sistemas financieros y la supresión de normas regulatorias, junto con los cambios tecnológicos en las redes informáticas que han integrado mercados financieros diversos, han supuesto que el riesgo operacional ha tomado una importancia incluso que el riesgo de crédito.

En los Estados Unidos de América la regulación bancaria de 1933 (*Glass-Steagall Act*) imponía unas restricciones importantes en el sector financiero. La división entre bancos comerciales orientados hacia la captación de depósitos y el crédito, y los industriales o de inversión, dedicados a proveer fondos a las grandes empresas y a la emisión de empréstitos, fue anulada en 1999 (*Financial Services Act*), permitiendo además una oferta de servicios financieros y de seguro a múltiples actores para los que estaba previamente prohibidas muchas operaciones financieras.

En Europa, en 1986 la reforma de la bolsa de Londres supuso un nivel de no regulación desconocido hasta entonces. Desaparecieron las comisiones fijas en las transmisiones de valores, las empresas financieras podían intervenir en la bolsa por cuenta propia o ajena, se automatizó el intercambio de acciones; en definitiva, se eliminaron restricciones consideradas, hasta entonces, propias de los mercados.

Otros factores importantes fueron la adopción del euro en la U.E. y los cambios en Europa del este; los mercados se abrieron a la competencia y se expandieron considerablemente. Los grandes procesos de privatización de empresas estatales introdujeron nuevos agentes, demandando financiación y productos financieros.

Los procesos de globalización se extendieron al sector financiero, incrementando enormemente la competencia entre éstos. Los inversores disponían así de más oportunidades de colocar sus fondos, y surgieron nuevos instrumentos y productos financieros, como los derivados, que permitían controlar riesgos de crédito y de mercado, o como la titulización de activos no líquidos, transformándolos en otros

líquidos. Algunos de estos productos originaron posteriormente unos problemas importantes en algunos países.

El desarrollo de Internet permitió la generalización del comercio electrónico y, de la banca electrónica, así como las comunicaciones y el intercambio de información financiera, induciendo a la formación de grandes corporaciones multinacionales. Recientemente, las dificultades en entidades 'demasiado grandes para permitirles caer' han puesto en peligro la estabilidad de países y regiones en el mundo.

Este entorno ha hecho crecer los riesgos operacionales de magnitudes desconocidas: desde los ataques cibernéticos a los fraudes en tarjetas de crédito, incluyendo los errores derivados del aumento del tamaño de los bancos y aseguradoras, y otros riesgos operacionales asociados a los nuevos productos financieros.

Como muestra de la importancia que ha tomado el riesgo operacional basta citar algunos ejemplos de desaparición de entidades importantes, o de dificultades en organismos o estados. El Banco BCCI sufrió importantes pérdidas debido a operaciones fraudulentas en 1991, así como el Bankers Trust, tres años más tarde. En 1994, el condado de Orange, en California, se declaró en quiebra, tras invertir en productos derivados de hipotecas, los cuales dependen de los tipos de interés; al aumentar éstos, las pérdidas ascendieron a más de 1700 millones de dólares. El banco Barings cayó en 1995 debido al fraude cometido por su director de futuros en Singapur, al operar con productos derivados en el SIMEX de Singapur y en la bolsa de Osaka; la falta de supervisión le permitió adquirir posiciones cada vez más altas y ocultar las pérdidas en una cuenta falsa. El banco Daiwa, perdió el mismo año, más de 1100 millones de dólares en operaciones con bonos del tesoro norteamericano; para cubrir las pérdidas, su vicepresidente ejecutivo, vendía valores de otros clientes. En 2002, el Allied Irish Banks descubrió un fraude interno, debido a operaciones que salieron mal, en una filial americana, con pérdidas superiores a 700 millones de dólares. En Enron Corporation, se forjó la mayor quiebra hasta la fecha, ocurrida en los EE.UU.; sus actividades en el gas natural derivaron hacia la actuación en los mercados de futuros de energía, ocultando

sus pérdidas de más de 750 millones de dólares mediante fraudes contables; con Enron cayó su auditor, Arthur Andersen, y afectó a otros bancos como Natwest, Citibanc, JPMorgan y otros. En 2005, más de cuarenta millones de registros de MasterCard fueron accedidos a través de la red, o United Parcel perdió una cinta con información de casi cuatro millones de clientes de Citigroup. Los ataques de septiembre de 2001 en Nueva York afectaron a varias empresas financieras importantes. En la última década se han producido hechos que muestran el nivel al que ha llegado a afectar el riesgo operacional: quiebra de Lehman Brothers, intervención del sistema bancario de Islandia, intervención de Fannie Mae y Freddie Mac, así como AIG y varias grandes compañías industriales, intervención del sistema bancario de Irlanda, actuaciones de los bancos centrales en Europa, etc. La mayoría de las pérdidas por riesgo operacional son de importe asumible y ocurren por circunstancias internas de cada organización; sin embargo, el hecho que alguna pérdida de gran magnitud puede poner en riesgo la existencia misma de una entidad, requiere que el control del riesgo operacional asuma una importancia esencial en la gestión del riesgo de las entidades.

Los *'hedge funds'* también han sufrido las consecuencias del riesgo operacional. Más del 50% de los problemas en estos se han debido al riesgo operacional, frente al 38% asociados al riesgo derivado de sus inversiones. Las causa más frecuentes de fallidos se han debido a una información falseada o deformada sobre las inversiones (en el 41% de las quiebras), uso indebido de los capitales destinados a inversiones por parte de los gestores (en el 30% de los casos), realización de inversiones en otras actividades distintas de las del fondo (14%), o simplemente, falta de recursos o de tecnología para la gestión del fondo.

El riesgo operacional se ha definido por exclusión, como la parte del riesgo que no es de mercado o de crédito, incluyendo el derivado de errores técnicos o humanos. La Asociación de Banqueros Británicos (2001) lo precisa como 'el riesgo de pérdidas derivado de procesos internos, personas o sistemas, fallidos o inadecuados, o de sucesos externos'. Aquí están incluidos los riesgos de tipo jurídico o legal, pero no el riesgo de imagen o de tipo estratégico. Algunos grandes bancos precisan esta definición de riesgo operacional asociándolo a pérdidas potenciales en relación a sus empleados,

las obligaciones contractuales, la documentación empleada, los fallos tecnológicos o de infraestructura, los desastres naturales, la influencia externa y las relaciones con los clientes. La S.E.C. estadounidense (2003) considera que es el riesgo de pérdidas debido a los fallos de control internos, como exceso en límites autorizados, operaciones de comercio no autorizado, fraudes en la operatoria o en las funciones de registros internos, personal no experimentado, incursiones no autorizadas en sistemas informáticos, siendo la relación no excluyente.

El riesgo operacional está influido por una serie de factores que pueden ser medidas indirectas: el volumen de ingresos o de negocio, el valor de los activos que están siendo gestionados, el valor y el número de transacciones, el número de empleados y sus años de experiencia, la estructura del balance en cuanto al ratio de deudas respecto a los recursos propios, el historial de pérdidas operativas y de reclamaciones a aseguradoras por este motivo. Los grandes bancos tienden a sufrir mayores pérdidas por riesgos operativos; en Chapelle *et al* (2005) se estima la relación

$$\frac{d \ln \text{Pérdidas}}{d \ln \text{Tamaño}} = 0.15$$

Los tipos de pérdidas originan la siguiente clasificación de riesgos operacionales: en función del origen del riesgo (interno o externo), por el efecto producido (directo o indirecto), por la naturaleza de las causas del riesgo (aleatorio o esperado), por el tipo de riesgo o de la causa, o por su magnitud y frecuencia de ocurrencia.

Los riesgos de crédito y de mercado han sido objeto de atención preferente desde hace años, dando lugar a modelos sofisticados. El riesgo operacional es más difícil de modelizar, pues existen muchos tipos de sucesos de riesgo que pueden ocurrir en cualquier departamento de una entidad. El gestor de riesgo de operación (*Operating Risk Manager*) necesita revisar toda la entidad. Como dificultad adicional cabe señalar la escasez de datos.

Para identificar los riesgos, hay que tener en cuenta los recursos que pueden dar origen a riesgos: equipamiento informático y su logicial, las bases de datos, las telecomunicaciones, etc. Una encuesta al nivel superior de gestión del banco es una forma de elaborar una lista, así como las estadísticas existentes de otras entidades. Los gestores de áreas deben relacionar los riesgos asociados a los procesos e información bajo su responsabilidad. El valor de cada uno de los recursos bajo riesgo, para el banco y para los posibles defraudadores, debe cuantificarse, así como las consecuencias derivadas de las posibilidades de ocurrencia. Hay que determinar los puntos críticos de la organización, a nivel de personas, equipamiento, seguridad informática, datos y la disponibilidad de copias de seguridad, los distintos usuarios internos y externos, personal técnico, y la documentación de los procesos y reglas de operatoria. Una vez relacionados estos riesgos potenciales y sus consecuencias, es preciso estimar las probabilidades de ocurrencia de cada tipo de suceso, para calcular las pérdidas esperadas y las respuestas a cada uno de estos sucesos. Por ejemplo, estos sucesos incluyen accidentes o actos deliberados, ataques internos o externos, destrucción de información o de equipos, saturación de los servidores, robos de información o de equipos, espionaje industrial, alterando o haciendo pública información reservada, robos de identidad, uso indebido de recursos, o siniestros en general.

El riesgo de crédito es el objeto fundamental de este trabajo; a veces se denomina riesgo de insolvencia (*default* en la literatura anglosajona). Está asociado a la posible pérdida originada por el hecho que una parte de los contratantes de una operación financiera no cumpla con sus obligaciones contractuales. Esto se traslada a la otra parte originándole un quebranto. Pero hoy día, este tipo de riesgo se ha extendido de forma notable, pues también se engloba dentro del riesgo de crédito el hecho que se puedan devaluar los activos de la contraparte de un acuerdo o contrato, aunque esta parte cumpla con los términos acordados como establece Schmid (2012).

La calidad crediticia de unos activos se puede deteriorar debido a múltiples causas. Algunas de éstas están asociadas a la evolución de la economía de la zona donde está ubicada la contraparte o de sus relaciones comerciales, es decir, a causas externas, o también cambios internos acaecidos a la contraparte de la operación, como puede ser su

solvencia, la disponibilidad o no de liquidez, o simplemente su deterioro económico-financiero.

Incluso, si se produce una reducción del nivel de calificación crediticia de una empresa por parte de una agencia calificadora, esto por si solo puede originar un deterioro de su solvencia, pues se pueden incrementar los costes de financiación, o incluso de pérdida de la cartera. De ahí la resistencia de las agencias a rebajar la calificación crediticia de los que son, en realidad, sus clientes. Incluso, en muchos contratos de productos estructurados, algunas cláusulas de la contratación, condicionan el desencadenamiento de acciones (por ejemplo, la resolución anticipada de un contrato), asociada a un deterioro de estos *ratings*.

Los inversores institucionales esperan que las pérdidas medias, o incluso las pronosticadas en una empresa, deben quedar cubiertas con los ingresos corrientes de ésta. Esto obliga a una dotación suficiente de recursos propios, incluyendo las reservas, para poder afrontar situaciones de pérdidas (que se producen aleatoriamente) con una cierta seguridad, medida en términos estadísticos de niveles de confianza. Las pérdidas que tienen muy baja probabilidad de ocurrencia no suelen provisionarse. En función del nivel de confianza de la estimación de pérdidas, la evaluación crediticia queda influida por éstas. En empresas de tipo financiero, como en el sector bancario o en el asegurador, el cálculo de las reservas está determinado por la calificación crediticia de sus activos.

En el riesgo de crédito hay que tener en cuenta del riesgo de contrapartida, asociado a la situación que puede tener un obligado al pago, su situación financiera y su posible dificultad de atender a sus obligaciones. El riesgo que se denomina 'país' se asocia al agregado de la solvencia de todas las contrapartidas incluidas en un área geográfica constituida como un estado.

Así, el riesgo soberano está regulado por el Banco de España, en su circular 4/1991. Un país al realizar importaciones asume unos compromisos de pago lo que afecta al riesgo

asociado a esta área geográfica, y a sus circunstancias económicas o incluso políticas, e incluso, recientemente habría que añadirle las sanitarias.

El riesgo administrativo está asociado a restricciones sobre las condiciones del mercado, la movilidad del capital, y las regulaciones sobre productos. En algunos casos suponen barreras que afectan a la situación económica de las empresas.

El riesgo político está asociado a medidas que puedan tomar los gobiernos afectando a los compromisos de pago o incluso a la propiedad. En los últimos años hemos asistido a varias expropiaciones que han afectado a empresas españolas en diversos países de Hispanoamérica, o a cambios en la política arancelaria, o incluso a cierre de fronteras, como en Ceuta.

La regulación de Basilea II (2004) especifica las condiciones bajo las que puede considerarse impago, quiebra o no atención de las obligaciones crediticias. Las entidades financieras evalúan el grado de fiabilidad de los activos de las empresas a las que financian, y de la capacidad de devolver las deudas.

Los factores que influyen en el riesgo de crédito son los siguientes. La contraparte, es decir el receptor de fondos en una operación financiera, y en el que va a estar concentrado el riesgo. Es preciso analizar sus estados contables, datos históricos, actividad y cualquier factor que incluya en la capacidad futura de pago. El fin para el que se demanda financiación y si ésta es suficiente es otro factor fundamental. El tipo de financiación y las garantías son que tienen que estar relacionadas con los capitales que se demandan y los plazos de devolución. Las garantías no son el núcleo de una operación de financiación, sino más bien el objetivo de ésta y si son realistas el planteamiento y el análisis financiero, pero tienen que estar valoradas correctamente, así como su liquidez, y si hay involucrados terceros que puedan afectar a su eficacia.

La teoría de carteras de Markowitz (1959), expuesta inicialmente en su tesis doctoral en Chicago, aborda la relación entre la rentabilidad y el riesgo (medido a través de la volatilidad de una cartera) al formar una cartera de inversiones alternativas. Estas dos variables, rentabilidad y riesgo están íntimamente relacionadas, y la determinación de la composición de una cartera óptima se alcanza mediante un proceso de optimización condicionada (se fija un tope de riesgo y se maximiza la rentabilidad, o se parte de una rentabilidad esperada, minimizándose la volatilidad).




Gráfico 2.2 Carteras posibles y eficientes (PW)

Fuente: Economipedia

La volatilidad se representa mediante la desviación típica de las rentabilidades observadas (función de un capital unitario invertido), y su relación con la rentabilidad esperada define el conjunto de carteras eficientes entre las distintas alternativas de inversión; esta frontera de Markowitz va variando según las condiciones de los mercados. En base a la función de utilidad de un inversor particular, se selecciona la inversión que maximiza esta utilidad, que, lógicamente, varía en función de la propensión al riesgo de cada uno. El problema práctico se centra en que los datos para realizar los cálculos para las carteras eficientes se hacen con valores pasados, por lo que existe una incertidumbre adicional respecto a la evolución futura de los activos que forman la cartera.

La rentabilidad está asociada al riesgo que se está dispuesto a asumir, pero también influye el tiempo en el que realiza la inversión, por lo que se puede representar una descomposición clásica




Gráfico 2.3 Rentabilidad en función del riesgo y de la duración

Fuente: www.encyclopediafinanciera.com

El modelo de Markowitz, en sus orígenes, presentaba problemas asociados al escaso poder de computación de la época, por lo que fue necesaria una forma menos exigente computacionalmente. Una simplificación fue debida a Sharpe (1964) que dio origen al modelo de valoración de activos (*Capital Asset Pricing Model*, CAPM) en el que se descompone el rendimiento de una cartera o de un activo financiero en dos componentes: la tasa libre de riesgo, y el llamado coeficiente *beta*, o volatilidad del riesgo.

No obstante, a partir de los noventa, los mercados financieros han creado activos cada vez más sofisticados. La valoración del riesgo se ha complicado, a partir de los productos derivados y la estructuración de activos (Crouchy *et al*, 2000). El riesgo de crédito se mide individualmente o como conjunto de riesgos de crédito de los activos que forman una cartera. También hay que tener en cuenta los destinatarios a los que va

dirigida esta valoración. Por un lado están las entidades financieras (que conceden financiación), como los modelos de *rating* desarrollados internamente. Por otro están los inversores que necesitan una evaluación externa objetiva; en este grupo están las evaluaciones de las agencias de acreditación, como S&P's, Moody's y otras. Finalmente, otros entes, como los reguladores, utilizan valoraciones de riesgo en sus actuaciones, como la determinación de reservas como requisitos de mínimos de fondos propios.

La gestión actual del riesgo persigue obtener rentabilidad en función del riesgo asumido. Las decisiones racionales requieren estimar la función de pérdidas y su distribución probabilística, para así evaluar la probabilidad de impago o la de transición a otro nivel de evaluación crediticia. Los paneles de expertos se han utilizado, aunque la tendencia es la modelización matemática y estadística para evaluar índices de tipo individual (en los EEUU, los métodos de *scoring* son ubicuos en los procesos de evaluación de operaciones financieras), y los *ratings* externos o internos son utilizados en la mayor parte de las emisiones de obligaciones. En un conjunto de créditos agrupados en una cartera, la función de pérdidas y su distribución, se obtienen a partir de la agregación de los riesgos individuales, que inicialmente, se han considerado independientes, pero que actualmente la tendencia es estudiarlos como magnitudes relacionadas.

Si no es posible la cuantificación de la distribución de fallido, el riesgo se convierte en incertidumbre. Y aunque se pueda estimar su distribución probabilística, no es posible anular la probabilidad de fallido, en la gestión de conjuntos de riesgo.

La situación de entorno financiero es cambiante, y en algunos aspectos impredecibles, lo que asocia un elemento de incertidumbre al riesgo, a pesar de usar modelos cada vez más sofisticados. Un ejemplo muy reciente es cómo ha afectado a la valoración de activos y a su rentabilidad la aparición de una pandemia como la del COVID-19, que ha originado una caída generalizada de las bolsas, de las carteras de valores, y,

consecuentemente de las decisiones de inversión en otros activos, que en gran medida se han visto afectadas e incluso paralizadas.

Hay sectores en la economía en los que la gestión del riesgo es de la mayor importancia. Las empresas de tipo financiero tienen que estudiar el riesgo de sus inversiones de una forma mucho más precisa que, por ejemplo, una empresa industrial. Un banco, que transforma pasivos a corto plazo en activos a largo, solo puede garantizar la liquidez de sus operaciones con una gestión del riesgo mucho más precisa; o una compañía de seguros o fondo de inversión, tiene que tener un control del riesgo de sus inversiones a un nivel tal que le permita atender los flujos de capital asociados a las obligaciones que tiene asumidas. Es decir, el funcionamiento de todo el sistema financiero requiere un control y gestión del riesgo que le permita atender sus obligaciones, además de cumplir con las obligaciones regulatorias

2.2. Cuantificación del riesgo

La gestión moderna del riesgo de forma sistemática se origina a partir del texto de referencia publicado por Mehr y Hedges (2012) inicialmente en 1973, seguido de otras publicaciones de los mismos autores. A partir de este trabajo pionero se ha desarrollado la teoría de gestión del riesgo, que se ha visto complementada con un desarrollo explosivo de los métodos estadísticos de valoración de activos financieros. La norma ISO 31000 describe como se debe implementar los sistemas de gestión del riesgo, desde el convencimiento del órgano gestor, seguido del diseño del entorno, la implementación del sistema de gestión del riesgo, su monitorización y revisión, hasta las medidas para mejorar el sistema global. En la figura se resume el entorno de gestión del riesgo asociado a esta norma ISO.

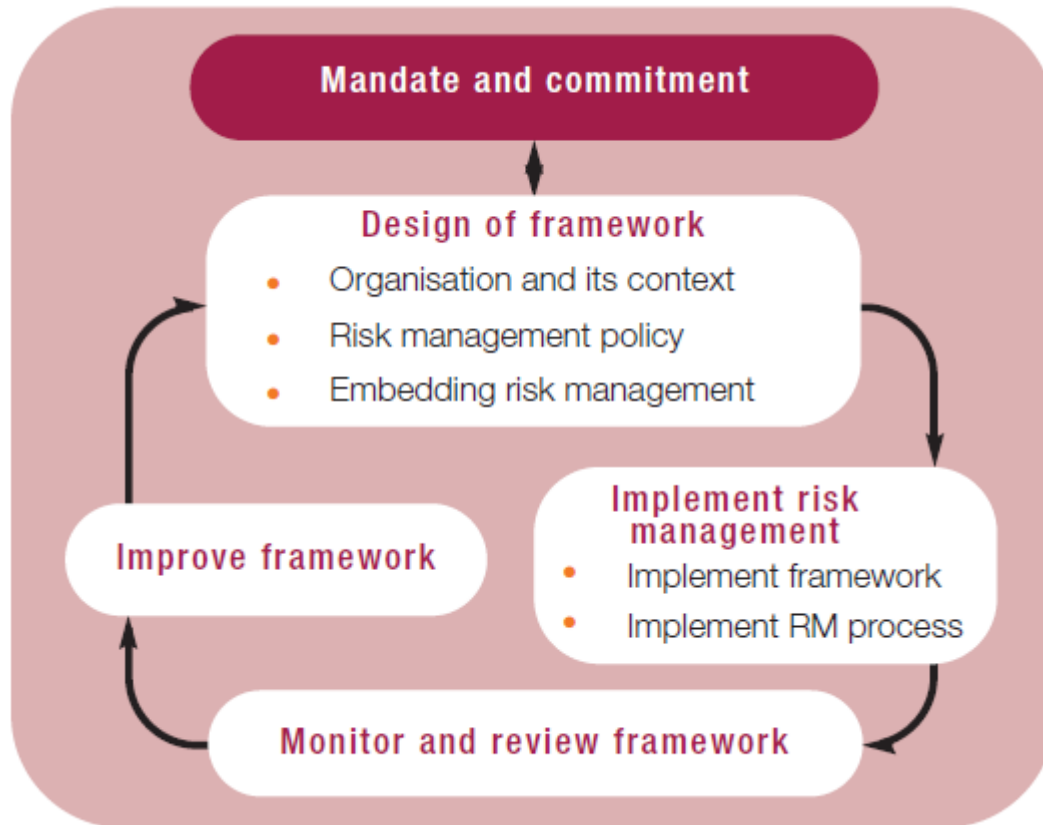


Gráfico 2.4 Sistema ISO 31000 de gestión del riesgo

Fuente: The Public Risk Management Association (2010)

El objetivo de la gestión del riesgo de crédito es la estimación del riesgo de pérdida asociado a operaciones activas, y la predicción de la posible insolvencia de la contraparte.

Un activo que forme parte de una cartera o conjunto de riesgos potenciales precisa que se pueda cuantificar. El valor en riesgo (*Value at Risk*, VaR) en un horizonte temporal (generalmente anual) se usa para determinar el riesgo de mercado. Requiere conocer la distribución probabilística de las pérdidas (y ganancias) y se obtiene, para un nivel de confianza dado, el cuantil correspondiente del valor a precio de mercado, con lo que se considera que el poco probable obtener pérdidas superiores a ese nivel.

Otros parámetros que se miden son la pérdida esperada (*Expected Loss*, EL), e incluso la pérdida no esperada (*Unexpected Loss*, UL).

En el caso empresarial, su rendimiento se mide utilizando distintos parámetros. La rentabilidad sobre los activos (*Return On Assets*, ROA) o sobre el capital (*Return On Equity*, ROE). La rentabilidad ajustada al riesgo (RAROC) mide la rentabilidad esperada dividida por una medida de riesgo, como puede ser la volatilidad de la rentabilidad o a la probabilidad de riesgos extremos.

Altman (2010) ha desarrollado un método, denominado *Z-score*, desarrolla un método de definir estratos de riesgos de una cartera (los estratos son internamente lo más homogéneos entre sí, y lo más diferenciados posibles unos con otros). Los datos base para evaluar los riesgos se basan en entidades o activos con riesgo de insolvencia y otros que no soportan esta situación. A partir de la crisis financiera de 2007 se produce un notable incremento en los fallidos y en quiebras de compañías. Dos años más tarde en los EEUU más de 200 grandes empresas entraron en suspensión de pagos, con activos en riesgo superiores a seiscientos mil millones de dólares.




Gráfico 2.5 Número de suspensiones de pagos y cantidades afectadas

Fuente: Altman (2010)

El objetivo es elaborar un sistema de puntuaciones para empresas no financieras, con predicción del instante de fallido y su probabilidad. Se analizan numerosas variables financieras, como la liquidez, el apalancamiento, tamaño de la empresa, dividendos, liquidez, cobertura de intereses, resultados financieros, valor bursátil, volatilidades, y otros. Varias de estas variables se utilizarán en el capítulo V en los modelos para predecir el *rating* a largo plazo de compañías.

El modelo evoluciona en el tiempo para adaptarse no sólo a las grandes empresas, sino también a las medianas. En un horizonte de cinco años, se predice el 70% de los fallidos, aumentando al 96% en el plazo de un año.

La medición del riesgo de crédito depende de varios factores causales. La probabilidad de fallido (PD) que un evento de crédito ocurra en un período de tiempo es la medida básica para la gestión del riesgo de crédito. Se puede estimar a partir de datos de mercado, mediante las frecuencias de fallidos, a partir de las cuales se calcula la esperanza de fallido (*Expected Default Frequencies*, EDF); para ello Moody's utiliza el modelo KMV, aunque también se estima mediante los *spreads* de algunos productos financieros como los *Credit Default Swaps* (CDS). Las agencias de crédito como S&P's y otras disponen de modelos internos para estimar la EDF.

Para cada nivel de *rating* se obtiene la PD, que es casi nula para los bonos de máxima calificación, y va creciendo a medida que disminuye la puntuación del activo o empresa. Para ello se obtiene la media de las frecuencias sobre un intervalo de tiempo. El logaritmo de la PD va aumentando linealmente al disminuir el nivel de *rating* (Bluhm *et al*, 2003).

Otro parámetro usual es la exposición al riesgo (EAD) o cantidad que vence en el futuro para una entidad. La parte dispuesta es el riesgo realmente soportado en el caso de producirse el fallido. Así la EAD es la suma de la parte utilizada y la proporción p del resto hasta el total comprometido. Esta parte p es evaluada y estimada. La EAD tiene carácter aleatorio pues existen factores afectados de incertidumbre, como el instante en

el que se produce el fallido o la parte dispuesta del importe, además de otros factores del mercado.

Otra medida del riesgo es la pérdida en caso de fallido (*Loss Given Default*, LGD) que es la esperanza matemática de la función (aleatoria) de pérdidas. Depende de varios factores, como pueden ser las garantías, su calidad, el orden en que los acreedores pueden reclamar su parte, etc. Como los datos históricos suelen ser escasos, y no contemplan todos los posibles valores de pérdidas, es necesario usar distintos modelos probabilísticos de tipo paramétrico, con los cuales se estima la severidad esperada para cada riesgo. En el caso de fallidos de muy baja probabilidad algunos modelos como los de Weibull o de Gumbel o distribuciones compuestas para agregados de pérdidas de una cartera; en otros casos, para el número de pérdidas se utilizan familias de distribuciones discretas. De esta forma se obtiene la variable aleatoria de pérdida agregada. Los datos sobre los sucesos ocurridos con operaciones de préstamo pasadas o de grupos de préstamos son empleados, así como otras variables relacionadas con los activos, incluyendo la calificación crediticia del prestatario.

Adicionalmente se estudia otra medida de riesgo que es la magnitud (aleatoria) ‘instante’ en el que se produce el suceso de crédito.

Una gran parte de los activos se someten a operaciones de aseguramiento, generalmente usando productos financieros que cumplen estas tareas. Estos disminuyen las pérdidas (L) y permiten calcular la pérdida esperada (*Expected Loss*, EL), mientras que la parte no esperada (UL) debe ser cubierta con recursos propios. Con la distribución de la función de pérdidas se estiman estas magnitudes.

La esperanza de pérdida, EL se obtiene como producto de la probabilidad de fallido, PD, por la severidad o pérdida, por la EAD.

En el caso que esté relacionas la ocurrencia del suceso de riesgo, no es posible realizar el cálculo anterior.




Gráfico 2.6 Distribución de pérdidas y valores esperados de pérdidas

La distribución de pérdidas se suele estimar aproximándola mediante distribuciones teóricas. Además de los modelos KMV de Moody's y de CrediMetrics, que estiman las PD y las EDF, también se usa el modelo de Merton (1974) que usa para valorar un activo, A , la ecuación diferencial estocástica $dA_t = \mu A_t dt + \sigma A_t dW_t$, en la que μ representa la rentabilidad media, y σ su volatilidad; W_t es un proceso browniano. Esta formulación se usa para valorar numerosos productos financieros.

2.3. Modelos para riesgos individuales

El modelo de riesgo individual se basa agregar las pérdidas esperadas para cada uno de los riesgos que forman una cartera, en contraposición al modelo de riesgo colectivo en el que se valora el riesgo de la cartera como un todo. En el caso actuarial, se supone que cada elemento de la cartera a lo sumo puede originar una pérdida. Las medidas del riesgo de crédito han tomado una importancia creciente en las últimas décadas debido a una serie de factores, como un incremento sustancial de las quiebras empresariales, las crisis económicas y la financiera del año 2008. la tendencia a no utilizar intermediarios

en las operaciones activas por las empresas más importantes, la competitividad creciente en los mercados financieros, las situaciones que se han producido en conocidos casos de la sobrevaloración de los activos empresariales, y el crecimiento de instrumentos de crédito que no figuran en los balances, como algunos productos derivados.

Los modelos para riesgos individuales se analizan generalmente cuantificando tres características:

- los indicadores de riesgo,
- las exposiciones al riesgo, y
- la evaluación del riesgo.

Los primeros constituyen unas herramientas cuantitativas para prever la ocurrencia de sucesos de riesgo; por ejemplo, los incumplimientos de las obligaciones crediticias o los cambios de categorías de *rating*. El valor real de los activos de una empresa son indicativos de la situación de ésta, y así es empleado por algunos modelos como el KMV. Sobre distintos riesgos individuales pueden influir causas comunes, lo que originan relaciones entre distintos riesgos individuales, y esto afecta al valor de los activos y a las probabilidades de fallido.

Las exposiciones al riesgo se derivan de la incertidumbre inherente a los mercados y a la situación económica en general. Existen varias magnitudes que permiten obtener información sobre este punto, como la exposición en el momento de incumplimiento (*Exposure At Default*, EAD), o la severidad (*Loss Given Default*, LGD) que consiste en la proporción sobre la exposición al riesgo que no se espera recuperar si sucede el suceso de incumplimiento. Se emplean para cuantificar las pérdidas asociadas al riesgo de crédito, habitualmente ligadas a diversos instrumentos financieros. La estimación de la severidad se puede hacer usando estadísticas pasadas, descontando los flujos que se producen en los procesos de recuperación de los casos en los que se ha producido el incumplimiento; si no existe esta información pasada, se pueden usar datos estadísticos disponibles sobre los mercados. La severidad depende de diversas circunstancias, como

el tiempo en mora, el tiempo desde la contratación, la valoración del préstamo, y la puntuación o *rating* asociado.




Gráfico 2.7 Severidad de distintos productos en España en función de la antigüedad

Fuente: BBVA

Finalmente, para evaluar el riesgo individual, es preciso hallar las variaciones del valor de los activos, cuando se producen los sucesos de crédito. El modelo CreditRisk+ se basa en calcular varias medias de riesgo como las pérdidas esperadas, el valor en riesgo VaR, o la pérdida esperada. Los modelos para evaluar este riesgo de crédito se suelen clasificar en estructurados, que tienen un fundamento económico-financiero claro, y los modelos de forma reducida. Entre los primeros están los de Black y Scholes (1973), el de Merton (1974) y el de Altman (1998). Los modelos de forma reducida tratan de estimar las tasas de fallidos y sus variaciones asociadas a factores de riesgo; entre estos está el citado CreditRisk+ y sus derivados (Deshpande, 2014).

Algunos modelos consideran como valoración los datos contables, mientras que otros usan valores de mercado o incluso el valor actual de los flujos de caja futuros.

Las entidades financieras suelen elaborar unos valores internos para estimar la probabilidad de fallido, y estos son comparados con los *ratings* proporcionados por las agencias. Los *ratings* internos suelen tender a replicar los externos. Y las técnicas estadísticas utilizadas suelen ser modelos logit o similares, y modelos de análisis

discriminante. En modelos de tipo comercial son muy habituales los métodos de *scoring*, basados en sistemas de puntuación. En el sector bancario estos métodos de puntuación se utilizan para la toma de decisiones en la concesión de créditos. Todos ellos se basan en la premisa que existen variables relevantes que informan sobre el riesgo, y que permiten determinar la probabilidad de fallido. Altman y Saunders, en diversos trabajos (1998, 2002, 2010) contribuyen en la elaboración de modelos de valoración del riesgo más complejos, y para productos derivados que pueden ocultar las verdaderas probabilidades de fallido al no figurar en los balances empresariales. La forma clásica de valoración de operaciones activas ha sido subjetivas, basadas en la reputación del solicitante de fondos, el capital y el apalancamiento crediticio, la volatilidad de los flujos de caja y las garantías aportadas.

Los métodos cuantitativos clásicos han funcionado razonablemente bien durante bastante tiempo, pero en épocas de crisis los riesgos han aumentado debido a las relaciones entre los componentes de las carteras que han tendido a comportarse de forma similar. En el modelo de Black, Scholes y Merton (o.p.) la probabilidad de fallido en un período de tiempo depende del valor de mercado de la compañía en relación a su deuda y de la volatilidad de sus activos. En el modelo KMV (1993) se precisan estimaciones de estas magnitudes, y se considera que el pasivo se puede considerar como una opción *call* sobre el valor del activo; y se incluye la relación entre la volatilidad del valor bursátil y la volatilidad teórica, es decir, no observable, de los activos empresariales. A partir de estos se obtiene la frecuencia esperada de fallido (*Expected Default Frequency*, EDF) para las empresas demandantes de fondos (el fallido se considera que ocurre cuando el valor de los activos bajan por debajo de las obligaciones crediticias a corto plazo). La 'distancia al fallido' se mide mediante el número de desviaciones típicas de la volatilidad bursátil sobre el valor de los activos.

Algunas técnicas de clasificación como las redes neuronales artificiales (Bhoge, 2019) se utilizan para la predicción del riesgo de crédito, pues se adaptan de forma práctica a las no linealidades y no requieren especificar una relación funcional con las variables predictoras, como los modelos econométricos clásicos. En el capítulo quinto se emplea este enfoque para predecir los *ratings* de S&P's y Moody's. Laplante y Rubtsov (2019)

desarrollan un modelo de uso de técnicas basadas en el aprendizaje automático en datos financieros, para evaluar el riesgo de crédito. Los riesgos de valoración de activos son estimados por Cheridito *et al* (2020) utilizando este tipo de modelos. Angelini *et al* (2008) usan modelos de riesgos basados en redes neuronales para analizar el riesgo para calcular el capital regulatorio requerido por los comités de Basilea. Varios autores rusos están proponiendo modelos de evaluación del riesgo empresarial; Kachalov *et al* (2018) proponen modelos para evaluar el riesgo estratégico en las decisiones empresariales.

Otros modelos utilizados en la clasificación del riesgo de crédito son los denominados 'máquinas de soporte de vectores' (*Support Vector Machines*, SVM), que utilizan fronteras no lineales y, usan funciones de núcleo para definir diversas alternativas (Mirjalili *et al*, 2019, y Goh y Lee, 2019). Khemakhem *et al* (2018) utilizan diversas técnicas de ingeniería de datos y de inteligencia artificial para cuantificar el riesgo de crédito, incluyendo redes neuronales y SVM. La idea básica de los SVM es definir hiperplanos óptimos para caracterizar configuraciones separables de casos, y extender los conglomerados que no son separables mediante transformaciones (definidas por funciones núcleo) para obtener conjuntos diferenciados en nuevos espacios. Los vectores de soporte son los casos más próximos a los hiperplanos de separación; son los casos más complicados de clasificar. La idea no está muy alejada de las redes neuronales, pero tienden a ser más robustos en la predicción de clasificaciones de nuevos casos, al optimizar la selección de los hiperplanos separadores entre los, generalmente, infinitos posibles. En las conclusiones de este trabajo, se propone como continuación del mismo, utilizar esta técnica para la predicción de *ratings*.

Existen otros modelos basados en analizar los diferenciales de crédito, entre los tipos libres de riesgo y los tipos de los productos financieros. Se establecen relaciones entre el valor del activo y las variables que definen las características con los diferenciales (*spreads*), y consecuentemente, estimar las probabilidades de fallido.

2.4. Modelos para riesgos relacionados

Los modelos de riesgos (cor) relacionados se refieren a los que representan carteras de activos en los que las situaciones de incumplimiento o de fallido están relacionadas. Así, en un conjunto de activos, la situaciones de fallido se representan con variables aleatorias que, en general, no son independientes, por lo que, al evaluar el riesgo de la cartera en su conjunto, la situación es más compleja que si los sucesos de fallido fueran independientes. Por ejemplo, las cantidades en riesgo de la cartera sería una magnitud aleatoria cuya distribución podría abordarse mediante técnicas de agregación de variables aleatorias, es decir, mediante convoluciones. Sin embargo, en el caso de riesgos relacionados, es más complejo determinar la distribución del riesgo total, y requiere modelos más sofisticados. Los desarrollos teóricos originaron modelos más complejos para analizar riesgos individuales, y sobre todo, se crean nuevas herramientas para valorar conjuntamente carteras de riesgos, en los que se tienen en cuenta las interrelaciones entre las probabilidades de fallidos de elementos de una cartera, y para valorar financieramente el riesgo de crédito. También se incorporan los riesgos que figuran fuera del balance de las empresas.

Una cuestión terminológica es la expresión 'riesgos correlacionados' en lugar de 'riesgos relacionados'. La correlación entre dos variables aleatorias o dos conjuntos de datos es una medida de asociación lineal, y, la relación entre las distribuciones de riesgos relacionados no tiene que ser lineal. No obstante, en la literatura se utiliza el término 'riesgos correlacionados'.

Recíprocamente, la incorrelación no implica independencia entre los riesgos individuales; tan solo la ausencia de distribución lineal, salvo en el caso en el que la distribución conjunta de los riesgos individuales se ajuste a una normal multivariante, en cuyo caso la incorrelación y la independencia son equivalentes.

Y, no hay que olvidar que la correlación no implica relaciones causales, lo que dificulta adicionalmente la medida global del riesgo.

Además, existen infinitas distribuciones multivariantes no normales con una estructura de correlaciones predeterminada y con distribuciones marginales normales. Como muestra, se van a mostrar tres distribuciones obtenidas mediante simulación, de una variable bivalente (X, Y), para la que $\rho_{XY} = 0.7$, y se verifica que $X, Y \in N(0; 1)$.




Gráfico 2.8 Distribución Normal bivalente




Gráfico 2.9 Distribución bivalente no normal con marginales normales

Fuente: García (2001)

¿Qué consecuencias puede tener esta situación para una medida global del riesgo? Es decir, que aunque los riesgos individuales puedan considerarse normales, ¿Cómo

afectaría al riesgo global? El hecho de la posibilidad de 'colas alargadas' origina un incremento del riesgo que puede no detectarse si se asume una hipótesis de normalidad multivariante.

En la evaluación de *ratings* de empresas se considera la situación de posible fallido, es decir, es un modelo binario. Algunos modelos para una cartera de activos o de empresas de un sector, consideran un conjunto de variables binarias asociadas a cada uno de ellos; la agregación de estas variables binarias representa la frecuencia de fallidos (durante un cierto período de tiempo, generalmente un año) en el conjunto de riesgos considerados.

Algunos modelos que utilizan este planteamiento son el modelo CreditMetrics de RiskMetrics Group (2007), que tiene en cuenta el riesgo de contraparte para conjuntos de datos escasos, con los que se obtiene un modelo de volatilidad incondicional, que permite calcular el valor en riesgo (VaR), y cuyo esquema, se muestra a continuación. La metodología se resume en el trabajo de Ravshanbek (2017).

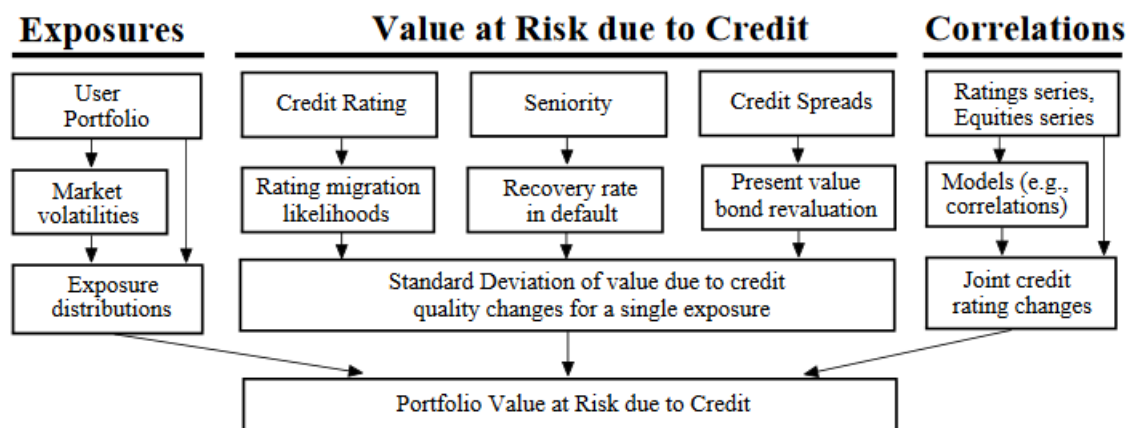


Gráfico 2.10 Esquema del modelo CreditMetrics

Fuente: RiskMetrics Group

La metodología no requiere ninguna hipótesis de normalidad, y tiene en cuenta las probabilidades de transición de un nivel de *rating* a otro, cuya matriz de transición se estima a partir de datos históricos de más de 20 años.

Otro modelo que usa un enfoque similar es el KMV, que estima la frecuencia esperada de fallido (*Expected default frequency* - EDF), y está basado en el valor estimado de la empresa; la información del mercado se considera incluida en la cotización de la empresa y en los estados contables, que se resumen en el riesgo implícito de fallido.




Gráfico 2.11 Valor esperado de la empresa en el instante T de vencimiento de la deuda

Fuente: Moody's

Las probabilidades de fallido se basan en el valor de mercado de la empresa y su volatilidad, calculándose un índice o distancia al riesgo incurrido, y este valor se traslada a probabilidades de fallido en base a información previa. Tiene la ventaja de ajustarse a las fluctuaciones y ciclos del mercado, para la detección del deterioro de la calidad crediticia. Tiene la ventaja de adelantarse a los cambios de ésta, de forma anticipada a los cambios de *rating* de S&P's y Moody's. El valor EDF proporcionado es numérico a diferencia de los *ratings* ordinales de estas agencias. No obstante, requiere la hipótesis a priori de normalidad multivariante.

Otro modelo es cuando el número de fallidos se puede representar mediante una distribución de Poisson. El número total de fallidos en una cartera es la suma de variables de Poisson, que, en el caso de independencia entre fallidos, también seguirá

una ley de Poisson. Sin embargo, si están relacionados, la distribución es una mixtura. Si los riesgos son similares, se tiene una cartera de Poisson uniforme.

Los modelos basados en mixturas de variables binarias se usan para representar distribuciones de fallidos relacionados, cuya relación viene definida a partir de la matriz de covarianzas de estas variables binarias (Boland, 2007). Si los riesgos tienen probabilidades de fallido y estructuras de covarianzas idénticas y positivas, es decir, si la cartera es uniforme, a mayor variabilidad entre las probabilidades de *default*, se incrementa la probabilidad de pérdidas.

Además de los modelos ya citados, el KMV y el CreditMetrics, es habitual del modelo Credit Portfolio View, de la compañía Mc Kinsey, que se basa en puntuar la cartera teniendo en cuenta las interrelaciones entre la ocurrencia de fallidos y la situación del ciclo económico.

Los modelos KMV y el de CreditMetrics utilizan también distribuciones de tipo cópula, pues es frecuente que los distintos activos que constituyen una cartera tengan distribuciones marginales de su rentabilidad diferentes, y relaciones no lineales y asimétricas.

Las cópulas surgen para poder representar este tipo de situaciones. Para llegar al concepto de cópula, se parte de una distribución uniforme o rectangular $R(0; 1)$, y si se tiene una variable aleatoria, X , cuya función de distribución es $F(x)$, se verifica que la variable aleatoria definida mediante $Y = F(X) \in R(0; 1)$, y, a partir de una distribución rectangular, con la transformación F^{-1} se obtiene la distribución de X .

Una cópula bivalente es una variable aleatoria bidimensional, C , cuyo espacio muestral es el cuadrado $[0; 1] \times [0; 1]$ y que tiene distribuciones marginales uniformes $R(0; 1)$; siendo además $C(y_1, 0) = 0 = C(0, y_2)$, $C(y_1, 1) = y_1$, $C(1, y_2) = y_2$, debido a ser

rectangulares las distribuciones marginales, y si $y_1 \geq y_1^*$ y $y_2 \geq y_2^*$ valores contenidos en el intervalo $[0, 1]$, se verifica que $C(y_1, y_2) - C(y_1^*, y_2) \geq C(y_1, y_2^*) - C(y_1^*, y_2^*)$. El teorema de Sklar (Giacomini, 2005) establece que dada una función de distribución $F(x_1, x_2)$ de una variable aleatoria bidimensional, cuyas marginales son $F_1(x_1)$ y $F_2(x_2)$, se tiene que existe una cópula C , tal que $C(F_1(x_1), F_2(x_2)) = F(x_1, x_2)$, y, recíprocamente, la cópula C , permite reproducir una distribución bivalente, con las marginales dadas. Si estas son continuas, la cópula está unívocamente definida. Además, dada una variable bivalente de función de distribución $F(x_1, x_2)$ y distribuciones marginales $F_1(x_1)$ y $F_2(x_2)$, se define la cópula implícita $C(y_1, y_2) = F(F_1^{-1}(y_1), F_2^{-1}(y_2))$, que es la probabilidad que las variables X_1 y X_2 sean menor o igual que sus respectivos cuantiles y_1 e y_2 . Así, es posible generar una cópula a partir de una distribución bivalente, usando sus funciones de distribución marginales, e introduciendo una estructura de dependencia entre ellas.

Por ejemplo, una cópula gaussiana es la cópula implícita correspondiente a una variable Normal multivariante $N(\vec{0}; \Sigma)$ con marginales $N(0; 1)$, cuya función de distribución se representa mediante Φ ; en el caso bivalentes, es

$$C(y_1, y_2) = F(\Phi^{-1}(y_1), \Phi^{-1}(y_2)) = \int_0^{\Phi^{-1}(y_1)} \int_0^{\Phi^{-1}(y_2)} \frac{1}{2\pi} \frac{1}{\sqrt{1-\rho^2}} e^{-\frac{1}{2(1-\rho^2)}(x_1^2 - 2\rho x_1 x_2 + x_2^2)} dx_2 dx_1$$




Gráfico 2.12 Densidades de cópulas normales con correlaciones respectivas $\rho = 0.5$ y -0.25

Fuente: Novales (2017)

Esta cópula gaussiana es simétrica; las rentabilidades financieras suelen estar más correlacionadas cuando son negativas y de valor absoluto elevadas, que cuando son positivas, por lo que la dependencia es asimétrica. Una cópula suele presentar valores elevados en las ‘colas’ y reducida en el centro del espacio muestral de las variables aleatorias a las que está asociada como se aprecia en la figura.

Los resultados anteriores se generalizan para variables multivariantes.

Se suele establecer las cópulas implícitas, elaboradas a partir de una distribución conocida, como la Normal o la t de Student, y cópulas explícitas, que tiene una forma propia, generalmente simple; otro tipo de cópulas son las arquimedianas (continuas, estrictamente decrecientes y convexas), que son explícitas, como la de Gumbel, la de Clayton o la de Frank.




Gráfico 2.13 Densidades de cópulas de Gumbel y Clayton

Fuente: Bolancé *et al* (2015)

Las cópulas permiten modelizar un conjunto amplio de conjuntos de variables aleatorias dependientes, como las que surgen en la representación de riesgos relacionados. Y además utilizar medidas de asociación distintas de los coeficientes de correlación, incluyendo coeficientes de dependencia de valores extremos. Por ejemplo, para una cópula bivalente, el coeficiente de dependencia de la cola derecha se representa mediante

$$\lambda_y = \lim_{y \rightarrow 1^-} \frac{1 - C(y, y)}{1 - y}$$

Una cópula contiene información sobre el tipo de interrelaciones existentes entre las variables aleatorias que la generan, es decir, que puede considerarse asociada a la distribución conjunta con marginales iguales a las distribuciones que la componen, incluyendo la dependencia entre las variables marginales. Para variables aleatorias continuas, si se les somete a unas transformaciones estrictamente crecientes, la cópula asociada resulta ser invariante, con lo cual las cópulas constituyen una herramienta natural para representar situaciones de dependencia variadas.

El valor en riesgo, VaR, es una medida de cuantificación del riesgo asociado a una cartera, representando la máxima pérdida posible medida con una confianza $1 - \alpha$. Es decir, que la pérdida máxima esperada no puede superar al VaR con la confianza predeterminada. Para calcularlo, es necesario especificar las distribuciones de pérdida, pues este valor es el cuantil asociado a una probabilidad α predeterminada, la cual depende de la distribución conjunta de los riesgos relacionados que forman la cartera. Hay que tener en cuenta que estas relaciones implican distribuciones con valores extremos, es decir, que no es posible usar hipótesis a priori de tipo Normal, que no encajan en dependencias no lineales. Las cópulas incluyen relaciones complejas de dependencia que son adecuadas para situaciones como las que se presentan en el mundo financiero.

En la valoración del riesgo, es frecuente que se tomen medidas sobre los precios en relación a la rentabilidad de los activos, para así mejorar el rendimiento de carteras de activos. Bessis (2007) propone unas medidas para estimar los precios asociados a cada operación (*Risk-based pricing*) en función de sus expectativas y de la rentabilidad requerida como base para incluir el tipo de interés considerado como libre de riesgo, la pérdida relativa esperada por asumir el riesgo de crédito y la prima de riesgo interpretada como coste del capital prestado. Otra medida es el RAROC (*Risk-Adjusted Return On Capital*), que representa la rentabilidad final, ajustada al riesgo, es decir el beneficio neto dividido por el capital de la operación. A veces se usa la expresión RAR para esta medida. El valor añadido para los propietarios o accionistas, SVA

(*Shareholders Value Added*) tiene en cuenta la rentabilidad para los accionistas y las transacciones realizadas con las carteras es otra medida de valoración del riesgo. Finalmente, el 'ratio de Sharpe' es otra medida que relaciona el riesgo de una cartera con su rentabilidad, teniendo en cuenta las esperanzas de beneficios y del riesgo, y sirve para comparar la situación de riesgo con alternativas previstas.

2.5. Los estados contables y el riesgo

Los estados contables y financieros recogen de forma ordenada la información sobre la situación de una empresa en un momento dado y sobre un intervalo de tiempo (generalmente, un año, aunque también se suelen estudiar relacionándolos con períodos más cortos).

El análisis económico-financiero persigue obtener una visión de conjunto sobre las magnitudes contenidas en los estados contables y financieros de una empresa, y su situación general. En él se tienen en cuenta la evolución temporal, dentro del ejercicio y comparándolos con los de ejercicios anteriores, así como la influencia de sucesos externos. El análisis de todos estos factores y los cambios inducidos, permite evaluar la posición de una empresa y su evolución futura.

Los tres parámetros básicos que se suelen analizar son la rentabilidad, la liquidez y la solvencia. El riesgo financiero depende de la variabilidad del rendimiento o rentabilidad esperada, es decir de la volatilidad de los resultados empresariales, y de su evolución en el tiempo. Cuando se estudia un ejercicio se suele hablar de análisis vertical, y cuando se consideran los estados de varios años, de análisis horizontal. Las desviaciones respecto de los valores esperados son los que sirven para cuantificar la evolución del riesgo.

Los estados financieros deben incluir magnitudes que sean fiables, es decir, que se deriven de operaciones contabilizadas de acuerdo con los principios contables y las normas adoptadas a nivel global.

El primer elemento de los estados contables es el balance, que es un estado financiero estático, es decir referido a un instante de tiempo, en el que se incluyen la información económica y financiera de la empresa; consta de tres elementos: el activo y el pasivo, por un lado, y el patrimonio neto de la empresa.

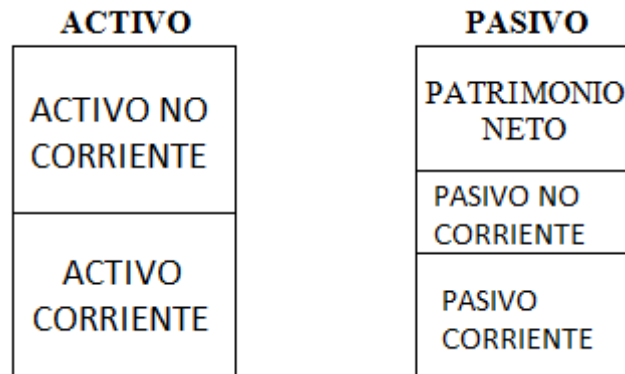


Gráfico 2.14 Esquema del balance

Fuente: Economipedia

El balance proporciona información sobre la calidad de sus distintas partidas, así como del estado de liquidez y la solvencia. Su evolución temporal permite conocer cómo evoluciona el patrimonio. En el activo figuran el destino de los recursos financieros de la empresa; el activo no corriente incluye las inversiones duraderas, clasificadas en inmovilizado material, inmaterial y financiero; los bienes que se incluyen en estas partidas se mantienen períodos largos, teniendo en cuenta su depreciación; mientras que en el activo corriente se encuentran las inversiones a corto plazo, incluyendo las existencias, las deudas de clientes y la tesorería. Los elementos del activo se clasifican de menor a mayor liquidez, esto es, si es menos o más posible el convertir sus partidas en efectivo. La estructura del activo de una empresa dependerán de su actividad; por ejemplo, en una empresa bancaria puede haber un inmovilizado financiero importante, así como predominará el activo corriente; en una empresa industrial suele predominar el activo no corriente por la necesidad de mantener una inversión importante en inmovilizado. En el pasivo se encuentran las fuentes de financiación de la empresa. Así en el pasivo no corriente estarán los recursos cuya exigibilidad (deudas) sea a largo

plazo, o incluso no sean exigibles, como los recursos propios (capital, reservas y el resultado del ejercicio). En el pasivo corriente se concentran los recursos cuya exigibilidad sea a corto plazo (generalmente inferior al año), como las deudas a corto plazo, o las deudas con proveedores. De nuevo, la estructura del pasivo dependerá del tipo de actividad; un banco dispondrá de un gran volumen de pasivo a corto plazo (los depósitos de sus clientes) que se transformará en activos a medio y largo plazo (los préstamos y créditos concedidos), y unos recursos propios más escasos; igual ocurre con una cadena de almacenes, que tendrá una cuenta de proveedores muy abultada (que le financian su actividad) en relación a los recursos propios, mientras que una empresa industrial tenderá a financiarse con recursos a largo plazo y con recursos propios.

La cuenta de resultados incluye los ingresos y gastos durante un período de tiempo, y presenta los beneficios o pérdidas de la empresa, y su estructura. Entre los gastos se tienen los costes variables, que son proporcionales a la actividad o ventas, y los costes fijos, que no dependen del nivel de producción. Los costes directos son los que corresponden a la producción de la empresa, a productos específicos; los costes indirectos se imputan a diferentes productos simultáneamente, en función de variables que puedan desagregar estos costes.


Cuentas de Resultados			
Debe			Haber
COMPRAS	PÉRDIDAS	GANANCIAS	INGRESOS
GASTOS			VENTAS

Gráfico 2.15 Esquema de la cuenta de resultados

Fuente: Economipedia

La estructura de la cuenta de resultados permite calcular algunas magnitudes que informan sobre la salud financiera de la empresa, como el margen bruto o EBITDA (*Earnings Before Interest, Taxes, Depreciation and Amortization*), que incluye los

II. EL RIESGO Y SU CONTROL

ingresos y gastos ordinarios, antes de incorporar las amortizaciones y provisiones de reservas para distintos fines.

Cuenta de resultados
<u>Ingresos o ventas netas</u>
- Costes directos de los bienes vendidos
Margen Bruto
- Gastos generales, de personal y administrativos
<u>EBITDA</u>
- Gastos de amortización y provisiones
<u>Beneficio antes de intereses e impuestos (BAIT) o EBIT</u>
+ Ingresos extraordinarios
- Gastos extraordinarios
Resultado ordinario
+ Ingresos financieros
- Gastos financieros
Beneficio antes de impuestos (BAT) o EBT
- <u>Impuesto de sociedades</u>
<u>BENEFICIO NETO O RESULTADO DEL EJERCICIO</u>

Gráfico 2.16 Estructura de la cuenta de resultados

Fuente: Economipedia

Al incorporar estas últimas se obtiene el EBIT (*Earnings Before Interest and Taxes*) o margen de explotación, que es representativo de la capacidad de la empresa para generar beneficios. Tras incorporar los ingresos y gastos extraordinarios, se llega al resultado ordinario, y con los ingresos y gastos financieros, el beneficio antes de impuestos. La volatilidad de las ventas se relaciona con el concepto de 'punto muerto' que corresponde al nivel de ventas mínimo para empezar a tener beneficios. Si esta volatilidad es grande,

la empresa tendrá que operar sensiblemente por encima del punto muerto. En general, el operar muy por encima del punto muerto se asocia a menor riesgo.

El margen de beneficio neto es el ratio entre el beneficio neto y el volumen de ventas, es decir es el beneficio obtenido por unidad monetaria de ventas. De nuevo, unos mayores márgenes de explotación o de beneficio neto están asociados a menores probabilidades de fallido.

El estado de flujos de efectivo o caja (*Cash Flow*) contiene las transacciones que originan movimiento de fondos, y se mide con estimaciones directas, es decir el efectivo neto asociado a las operaciones, e indirecta; muestra la liquidez de la empresa. Es decir, muestra el origen de las corrientes de efectivo y su utilización, durante el ejercicio económico. Incorporan los flujos de efectivo de las actividades de explotación, inversión y financiación. Es una información fundamental pues sirve de predictor de posibles problemas, y para medir la capacidad de la empresa de pagar sus obligaciones, tanto de deudas, como de intereses y dividendos.

El cálculo del flujo de caja se realiza agregando una serie de partidas, que pueden ser, en algunos casos, negativas: los beneficios (o pérdidas) netas, las amortizaciones, las provisiones y el saldo neto de las cuentas por pagar menos las por cobrar. Si el flujo de caja es positivo, quiere decir que los ingresos son mayores que los gastos, mientras que si es negativo, es por lo contrario. Es un indicativo claro de la liquidez de la empresa (aunque no necesariamente de su solvencia).

El flujo de caja operativo es el efectivo generado por la actividad ordinaria, en ingresos sobre ventas e intereses cobrados de préstamos concedidos, así como dividendos por inversiones en otras empresas; incorpora los gastos operativos por compras, personal, impuestos e intereses pagados. Son el EBIT más los gastos de amortización menos los impuestos pagados.

A) FLUJOS DE EFECTIVO DE LAS ACTIVIDADES DE EXPLOTACIÓN

1. Resultado del ejercicio antes de impuestos.

2. Ajustes del resultado.

- a) Amortización del inmovilizado (+)
- b) Correcciones valorativas por deterioro (+/-)
- c) Variación de provisiones (+/-)
- d) Imputación de subvenciones (-)
- e) Resultados por bajas y enajenaciones del inmovilizado (+/-)
- f) Resultados por bajas y enajenaciones de instrumentos financieros (+/-)
- g) Ingresos financieros (-)
- h) Gastos financieros (+)
- i) Diferencias de cambio (+/-)
- j) Variación de valor razonable en instrumentos financieros (+/-)
- k) Otros ingresos y gastos (-/+)

3. Cambios en el capital corriente.

- a) Existencias (+/-)
- b) Deudores y otras cuentas a cobrar (+/-)
- c) Otros activos corrientes (+/-)
- d) Acreedores y otras cuentas a pagar (+/-)
- e) Otros pasivos corrientes (+/-)
- f) Otros activos y pasivos no corrientes (+/-)

4. Otros flujos de efectivo de las actividades de explotación.

- a) Pagos de intereses (-)
- b) Cobros de dividendos (+)
- c) Cobros de intereses (+)
- d) Pagos (cobros) por impuesto sobre beneficios (-/+)

5. Flujos de efectivo de las actividades de explotación (+/- 1 +/- 2 +/- 3 +/- 4).

Tabla 2.1 Esquema de cálculo del *cash flow*.

El flujo de caja de inversión es la variación de capital asociada a los instrumentos financieros empleados, como la deuda a corto o los gastos en inversiones y adquisiciones.

El flujo de caja financiero es el efectivo resultado de las entradas y salidas de capital asociados a la actividad económica de la empresa. Por ejemplo, la amortización del inmovilizado, las variaciones de inmovilizado, las pérdidas por operaciones financieras o las de tipo comercial o las de depreciación de mercaderías, o la dotación de capital para gastos de personal.

El flujo de caja libre es el efectivo generado después de atender al mantenimiento (o ampliación) de sus activos para mantener las operaciones. No incluye los intereses pagados pero sí los dividendos. Del flujo de caja operativo se quitan los gastos de capital, esto es, al beneficio neto se le suma las amortizaciones y se le quita las inversiones operativas y en activos fijos. Si es positivo, se está generando más efectivo que el que se precisa para cubrir los gastos y para hacer crecer el negocio.

La memoria anual sirve de complemento informativo a las cuentas anuales de las que forma parte. Es un informe de las actividades realizadas en el ejercicio. Incluye el informe de auditoría, herramienta esencial para paliar en parte la asimetría de información de los accionistas e inversores respecto a la calidad de los estados contables. También incorpora información sobre los criterios contables utilizados.

De las cuentas anuales se puede deducir la evolución de la actividad de la empresa, los costes fijos y variables, ingresos y ventas, su financiación, deudas y su estructura, y el margen de solvencia, los activos y su depreciación, la tasa de reposición de los productos almacenados, y el patrimonio neto. Es una información pública, aunque el obtener datos estadísticos de un número significativo de empresas no es tarea fácil. En nuestro caso se ha recurrido a grandes bases de datos, como las de Bloomberg, en la que

los estados contables de diferentes empresas, aparecen con un formato común, lo que facilita su posterior tratamiento.

La armonización de los principios de contabilidad es una necesidad para permitir tener una visión fiable y clara del significado de los estados financieros. El *International Accounting Standard Board* (IASB) norteamericano establece unos criterios reconocidos en los países desarrollados, y la Unión Europea ha establecido unas normas basada en estos principios, que ha dado lugar al Real Decreto 1514/2007, que adoptó en España las *Normas Internacionales de Contabilidad*.

Aunque los estados contables proporcionan información sobre la realidad económica y financiera de la empresa, se suelen calcular unos ratios para realizar comparaciones y para resaltar algunos aspectos del balance, de la cuenta de resultados o de los flujos de caja. Estos ratios permiten comparar los resultados sobre varios ejercicios y evaluar si se obtienen valores que se puedan considerar óptimos o aceptables.

Los ratios financieros tratan sobre la financiación de la empresa, es decir, sobre sus recursos propios y ajenos, y se obtienen del balance.

Los ratios económicos tratan sobre la rentabilidad, y se basan fundamentalmente en el contenido de la cuenta de resultados.

Algunos ratios usuales se reproducen a continuación.

a. Ratios de Solvencia

$$\text{Solvencia} = \text{Activo circulante} / \text{Pasivo circulante}$$

Grado de solvencia total (crece con la solvencia de la empresa)

Distancia al fallido de la empresa

$\text{Estabilidad} = \text{Pasivo no corriente} / \text{Activo no corriente}$

Proporción de pasivo exigible a largo financiado por activos fijos o de inversión

Valores superiores a la unidad indica que parte del activo fijo está financiado por pasivo exigible a corto plazo

$\text{Autonomía financiera} = \text{Fondos propios} / \text{Pasivo total}$

Proporción de los recursos propios de la empresa respecto a la financiación total

Valores mayores están asociados a mayor solvencia

También se puede incluir en el denominador el activo no corriente

$\text{Apalancamiento} = \text{Deuda total} / \text{Fondos propios}$

Proporción de deuda financiada con recursos propios

Al aumentar el apalancamiento, se incrementa el riesgo de fallido

A veces al denominador se le agrega la deuda total

$\text{Endeudamiento} = \text{Deuda financiera neta} / \text{EBITDA}$

Indicativo de la salud financiero al relacionar la deuda financiera (menos la tesorería) con el flujo de caja medido por el EBITDA

Valores mayores indican mayor endeudamiento en relación a la capacidad de generación de fondos

b. Ratios de liquidez

$\text{Liquidez} = \text{Activos corrientes} / \text{Pasivos exigibles a corto plazo}$

Capacidad de poder atender los pasivos exigibles a corto

Valores mayores indican mayor liquidez de la empresa

$\text{Test ácido} = (\text{Tesorería} + \text{cuentas por cobrar}) / \text{Pasivo exigible a corto plazo}$

Capacidad de atender los pasivos exigibles con liquidez casi inmediata

Valores mayores indican mayor liquidez de la empresa

$\text{Cash} = \text{Tesorería} / \text{Pasivo exigible a corto plazo}$

Capacidad de atender los pasivos exigibles con liquidez inmediata

Valores mayores indican mayor liquidez de la empresa

c. Ratios de rentabilidad

$\text{Margen de beneficio neto} = \text{Beneficio neto} / \text{Ventas}$

Proporción de beneficio por unidad de ingresos por ventas

Valores mayores indican mayor rentabilidad

$\text{Margen de resultado operativo} = \text{Resultado de explotación} / \text{Ventas}$

Proporción resultado por unidad de ingresos por ventas

Valores mayores indican mayor rentabilidad

$\text{Margen de EBITDA} = \text{EBITDA} / \text{Ventas}$

Medida de rentabilidad en relación al desempeño operativo

Se usa para comparar distintas empresas (pues elimina las cuestiones relacionadas con la financiación y las depreciaciones)

Valores mayores indican mayor rentabilidad

Otro similar es el margen de EBIT = $\text{EBIT} / \text{Ventas}$

Rentabilidad del activo ROA = $\text{Beneficio neto} / \text{Activo total}$

Proporción de beneficio por unidad de inversión

Valores mayores indican mayor rentabilidad

Rentabilidad del patrimonio ROE = $\text{Beneficio neto} / \text{Patrimonio neto}$

Proporción de beneficio por unidad de inversión de los accionistas

Valores mayores indican mayor rentabilidad

d. Ratios de actividad

Cobertura de intereses = $\text{EBITDA} / \text{Gastos financieros}$

Grado en que los intereses son absorbidos por el EBITDA

Valores mayores indican mayor capacidad de hacer frente a los pagos de intereses

Período medio de cobro = $360 \times \text{Clientes} / \text{Ventas}$

Número medio de días en que se cobra a los clientes

Período medio de pago = $360 \times \text{Proveedores} / \text{Ventas}$

Número medio de días en que se paga a los proveedores

y otros como el ratio de rotación de inventarios, el ratio de rotación del activo o del activo fijo.

e. Ratios sobre el flujo de caja

CFO sobre ventas = Flujo de caja operativo / Ventas

Proporción de efectivo generado por unidad de venta

Valores mayores indican mejores resultados

CFO sobre activos = Flujo de caja operativo / Activo total

Proporción de efectivo generado por unidad de inversión

Valores mayores indican mejores resultados

CFO sobre FP = Flujo de caja operativo / Fondos propios

Proporción de efectivo generado por unidad de recursos propios

Valores mayores indican mejores resultados

CFO sobre beneficio = Flujo de caja operativo / Beneficio operativo

Proporción de efectivo generado por unidad de las operaciones de explotación

Valores mayores indican mejores resultados efectivos

CFO sobre deuda = Flujo de caja operativo / Deuda total

Proporción de efectivo generado por unidad de deuda

Valores mayores indican superior capacidad de hacer frente a las deudas contraídas

$\text{Pay-Back} = \text{Deuda financiera total} / \text{Flujo de caja operativo}$

Anualidades en que la deuda podría ser pagada con los flujos de caja de las actividades operativas

Valores mayores indican más dificultad en atender a la deuda

Se puede considerar la deuda financiera neta.

En el capítulo V se emplean, además de variables correspondientes a los estados contables, algunos de estos ratios. Todos ellos se emplean en los modelos de predicción de *ratings*.

III. LAS AGENCIAS DE CALIFICACIÓN

3.1. Introducción

3.2. Evolución histórica

3.3. Puntuaciones elaboradas por las agencias

3.4. Normativa regulatoria

3.1. Introducción

Las agencias de calificación crediticia (*Credit Rating Agencies*, CRA) se han convertido en una parte fundamental de los mercados financieros. Emiten unas puntuaciones ordinales asociadas a la capacidad de las compañías, los gobiernos, organismos y empresas a cumplir con sus obligaciones financieras en los plazos establecidos. Tratan de proporcionar información objetiva sobre la salud financiera de sus evaluados (en su mayor parte, clientes). Esta puntuación se basa en dos componentes (Caridad *et al*, 2018): la primera parte obtenida de fuentes económicas y financieras, que pueden generalmente ser accesibles, y la segunda denominada 'datos cualitativos' sobre la que existe una información vaga.

Las evaluaciones se obtienen, en la mayor parte de los casos, a petición de las empresas o instituciones, que pagan por esta evaluación. Las puntuaciones obtenidas pueden ir modificándose a lo largo del tiempo. En algunos casos, las agencias rechazan emitir una puntuación, o, en otros, simplemente no existe información suficiente para poder emitir un juicio.

Los emisores de bonos y obligaciones precisan una calificación para poder acudir a los mercados, en los procesos de titulización, la estructura de los distintos tramos precisan de calificaciones (*ratings*), en los mercados denominados '*repo*' (un agente vende bonos del estado con un compromiso de recompra al día siguiente) precisan de los *ratings* para determinar las condiciones de los préstamos, los bancos y aseguradoras precisan las puntuaciones de sus activos para el cálculo de sus reservas, numerosos fondos de inversión están obligados a invertir sólo en activos con calificación crediticia por encima de un cierto nivel, en muchos contratos financieros se especifican que las garantías o la determinación de acciones, tengan un nivel mínimo en su *rating*.

III. LAS AGENCIAS DE CALIFICACIÓN

En definitiva, algo que se obtiene como una mera opinión, se ha convertido en una necesidad (incluso una obligación regulatoria) en una gran parte de las operaciones financieras.

La posibilidad de estimar los *ratings* directamente usando datos de los estados contables de las empresas fue abordada por primera vez por Merton (1974) en un trabajo fundamental, pero para analizar bonos empresariales y no las propias firmas. Se basaba en el análisis detallado de los estados contables, en los cuales el activo se puede considerar como una opción de tipo *call* (opción de compra) sobre los recursos de la empresa. De esta manera, si los activos son superiores a las deudas, es posible valorar la empresa exactamente igual que se valoraría esta opción, con lo cual el nivel de riesgo asociado a la deuda de la compañía puede establecerse en función del valor de la opción. Hay que indicar, para valorar la novedad de esta aproximación que solo un año antes apareció el clásico trabajo de Black y Scholes (1973) sobre la valoración de opciones mediante la resolución de una ecuación diferencial estocástica, trabajo que ha dado origen al desarrollo del moderno cálculo financiero para distintos tipos de productos derivados y estructurados. A partir de estos inicios se han publicado numerosos trabajos sobre la estimación de probabilidades de fallidos de activos financieros, tanto en los ámbitos académicos y empresariales como en la banca e instituciones financieras, y en las instituciones de inversión.

Los primeros intentos de desarrollar modelos estadísticos de predicción de frecuencias de fallidos en activos emitidos por entidades fueron desarrollados por Fons (1991); entre sus conclusiones cabe destacar que mas del 52% de la variabilidad en las frecuencias de fallidos, en el pasado, se podían asociar a tan solo dos factores: la calidad crediticia del deudor y el estado general de la economía. A partir de los resultados de este autor, Helwege and Kleiman (1996) elaboraron una metodología para explicar las variaciones anuales de las tasas de fallidos mediante un modelo uniecuacional cuyo coeficiente de determinación era de 0.81. Posteriormente, y derivados de los resultados anteriores encontramos varios modelos de Jonsson and Fridson (1996) para explicar las variaciones anuales en los *ratings* de Moody's (en el segmento de puntuaciones en los niveles especulativos), con un coeficiente de determinación de 0.86. La propia agencia Moody's, en 1999, elabora modelos de predicción de las frecuencias de fallidos, y otros modelos predictivos para las entidades/emisiones situadas en el nivel de grado

especulativo y para los productos con retrasos de un año en sus obligaciones, anticipando en doce meses (de forma intermensual).

Sobre la homogeneidad de los resultados, ya Kamstra, Kennedy y Suan, (2001), muestran que diferentes modelos (del tipo de variable endógena cualitativa) pueden conducir a distintas estimaciones de puntuaciones; y resaltan que es complicado a llegar a determinar un modelo óptimo. Usan distintos modelos econométricos para predecir los *ratings* de activos de renta fija en los sectores industriales y del transporte y logística en empresas valoradas por el servicio de calificación de bonos de Moody's. En las conclusiones afirman que modelos híbridos combinando resultados de diversos modelos logísticos ordinales proporcionan mejoras significativas, y de un orden de magnitud aceptable, sobre otros modelos existentes. Estas alternativas de modelización se basaban en un comportamiento no-markoviano en la evolución de los *ratings* (de hecho, en algunos modelos que se proponen más adelante, si se considera modelos con varios retardos sobre un período de varios años, se mejoran las predicciones de los *ratings*) y consideran posible heterogeneidad en las valoraciones industriales.

Otros autores como Frydman y Schuermann, (2008), resaltan que al estudiar los procesos dinámicos en la elaboración de *ratings* crediticios, es importante que el proceso de generación de puntuaciones sea markoviano y homogéneo en el tiempo, y se basan en análisis de evidencia empírica. Usan un modelo basado en mixturas de cadenas de Markov, considerando dos bloques de empresas, cuyo comportamiento markoviano es similar, pero cada uno, su evolución en el tiempo, se representa mediante una cadena distinta. De forma similar proceden Xing, Sun y Chen (2012), estimando las probabilidades de transición entre distintos niveles de puntuación crediticia suponiendo que el mecanismo subyacente es una cadena de Markov, en la que no se consideran puntos de interrupción no observados. Petropoulos *et al.* (2016) desarrollan un modelo para obtener el *rating* crediticio para empresas, en el que usan un enfoque del tipo modelo oculto de Markov (que habían sido usado en problemas de reconocimiento de formas), en el que los parámetros de la cadena son desconocidos, usando una distribución de Student (empleados en series temporales con datos extremos). Así partiendo de un conjunto de ratios financieros para obtener modelos de puntuaciones de crédito. Figlewski *et al.* (2012), usan formas reducidas de modelos econométricos del tipo de regresión semiparamétrica de Cox, adaptados de los modelos de análisis de supervivencia. En estos modelos, la función de riesgo para un emisor puede relacionarse con factores causales propios de esta firma, así como de otras variables relacionadas con

el entorno económico. Los modelos empleados se denominan 'reducidos' pues consideran que el suceso de riesgo que puede originar el fallido, puede ocurrir en cualquier instante aleatorio del tiempo; el otro enfoque es el que corresponde a los denominados modelos 'estructurales', en los que se considera el valor real o contable de la empresa, y el suceso de crédito ocurre cuando este valor baja de un nivel que se considera mínimo admisible. Huang, (2011), introduce el efecto de la crisis financiera asociada a las hipotecas *subprime*, con sus repercusiones en todo el sistema financiero y en especial en el bancario, lo que minusvaloró la capacidad de predecir los *ratings*, dado los fallos notables de las agencias de calificación y la pérdida de confianza generalizada en éstas a raíz de estos sucesos. Para contrarrestar los efectos, y con el objetivo de intentar mejorar las predicciones de las puntuaciones de crédito, utiliza procesos gaussianos basados en clasificadores núcleo.

Otros autores, como Cardoso et al. (2013), proponen un modelo de regresión bastante simple para estimar las probabilidades de fallidos, intentando replicar a los usados por las agencias de crédito; como variables explicativas usan los datos obtenidos de sus publicaciones de resultados financieros, y llegaron a concluir que el nivel de predicción era aproximadamente del 90% con una aproximación de más/menos tres niveles de puntuación crediticia (es decir, sobre intervalos móviles de bloques de siete puntuaciones). Un enfoque alternativo al uso de variables derivadas de los estados contables es el uso de ratios financieros, a partir de los cuales se puede predecir la probabilidad de fallido, de nuevo usando muestras sobre la evolución pasada de estos ratios. El programa RiskCalc, que está disponible para inversores a través del Servicio de Moody's para Inversores (2000), permite estimar frecuencias de fallidos en intervalos comprendidos entre uno y cinco años. Se basa en modelos de variable endógena cualitativa de tipo probit. Otros modelos como los KMV de Moody's (2002), estiman la frecuencia de fallidos esperada con un enfoque estructural; usan conjuntos de variables explicativas como la cotización de la empresa y su balance. No se centra excesivamente en la selección de las variables explicativas más importantes. Para abordar esta cuestión Yeh et al. (2012) proponen usar un modelo híbrido en el que incorporan árboles de decisión junto con información obtenida del mercado, y así estiman los *ratings* crediticios.

Una metodología alternativa para estimar los *ratings* (utilizado en esta memoria para obtener las puntuaciones de empresas de distintos sectores) consiste en utilizar datos públicos sobre los estados contables de distintas compañías, introduciéndolos en

modelos estadísticos y econométricos; Doumpou et al. (2015), utilizan un enfoque similar basado en modelos de clasificación empleando múltiples criterios; en ellos combinan datos de los estados contables, con los resultados de un modelo estructural, para mejorar el ratio de predicciones correctas. Y para contrastar la mejora en las estimaciones de *ratings* que se consiguen de esta forma con las de los propios modelos estructurales. El problema práctico de este enfoque es la disponibilidad de información estadística suficiente. En teoría, los estados contables de las empresas se incorporan a sus memorias anuales presentadas a sus accionistas. Pero cada una sigue una estructura propia al presentar sus balances, con mayor o menor desagregación. Esto supone un primer inconveniente real, pues para un tratamiento estadístico masivo, es necesaria una homogeneización en la presentación de los datos, lo que obliga a un trabajo previo sobre cada memoria de cada empresa. Pero, por otra parte, si se trata de incluir varios ejercicios, la búsqueda de la información es mucho más compleja. Y si este proceso se quiere repetir para varios centenares o miles de empresa, es prácticamente inabordable. La única alternativa es el acceso a grandes bases de datos de información estadística empresarial. Pero el coste de acceso es una barrera de entrada que impide poder realizar análisis con grandes muestras. Algunas universidades tienen acceso a BankScope, cuyo ámbito de datos son relativos al sector financiero. El servicio de Bloomberg proporciona acceso a decenas de miles de empresas con sus datos contables, calificaciones crediticias de las tres principales agencias e información general, con un ámbito global. Son estas últimas bases de datos las que han servido de fuente en este trabajo.

En la plataforma de Moody's existe un servicio de suscripción para obtener información sobre el balance de empresas así como una colección de ratios financieros, e incluso algo de lo que se identificó como información cualitativa. Engvall (2015), propone un conjunto de variables asociada a los estados contables de una empresa, incluyendo datos de beneficios, ratios de apalancamiento, medidas de liquidez, ratios relacionados con intereses pagados, y con el tamaño de la empresa; incluso con las variables denominadas 'Z-scores' de Altman (1968), que utilizó técnicas de análisis estadístico multivariante para caracterizar los fallidos empresariales.

Entre las variables relacionadas con la generación de beneficios empresariales, varias han sido empleadas como predictoras de los *ratings*. La más usual ha sido el ROA (Return On Assets) que relaciona los beneficios con el activo; se pueden encontrar propuesta por Kaplan and Urwitz (1979) al analizar las puntuaciones de emisiones de obligaciones. Ohlson (1980) emplea algunas variables adicionales, como

los rendimientos del capital, de los recursos propios, de las inversiones, el margen EBITDA, el margen bruto, el margen operativo, el ratio de ingresos netos con respecto al margen ordinario. También Gray et al. (2006) utilizan algunas de estas variables. Del mismo modo, los factores asociados a los márgenes disponibles se encuentran en los trabajos de Resti (2002), Resti y Sironi (2007), y de Amdouni y Soumaré (2014).

Otras variables empleadas en la explicación de las evaluaciones crediticias son los ratios de apalancamiento, como por ejemplo el de capital sobre el total del activo, o la deuda total a largo plazo sobre el capital o sobre los recursos propios. Kaplan y Urwitz (1979) utilizan el ratio de la deuda total sobre el activo; Gray et al. (2006), la deuda total sobre el valor bursátil, o de esta deuda total respecto al capital o respecto al total de activos así como el citado Resti (2002), o los citados Amdouni y Soumaré (2014) emplean el ratio EBITDA, o Gray et al (2006), el ratio EBIT. En algunos casos, en lugar de la deuda total se utiliza la deuda neta.

Las variables relacionadas con la liquidez son empleadas por varios autores citados anteriormente; Resti (2002) emplea un ratio de liquidez, además de un ratio de *cash flow* operativo respecto a la deuda y respecto a la deuda a corto plazo. Los ratios financieros relacionados con la cobertura de intereses son menos frecuentes, aunque el EBITDA sobre los pagos por intereses, o el cash flow respecto a estos pagos por intereses aparecen en el trabajo citado de Gray et al. (2006). En algunos casos se usa el EBIT directamente u otras variables relacionadas con el tamaño como el EBITDA o el total de ventas. En el trabajo de Engvall (2015) se muestra un resumen de variables que aparecen en la literatura reciente de estimación de *ratings*.

El Servicio para Inversores de Moody's (2017) presenta un conjunto de once variables o métricas (ratios), en los que además del ratio del EBITDA sobre los activos medios, figuran los gastos de intereses, el margen operativo o el FFO (fondos de operaciones - añadiendo la depreciación y la amortización menos las ganancias en ventas -) en relación a la deuda total, o la deuda en relación al EBITDA, además de otras variables. También señala Moody's que se pueden incorporar datos no públicos, es decir, lo que han denominado 'información cualitativa'. Al aplicar estas variables en las estimaciones de *ratings* se observa una tendencia clara en la figura siguiente.

III. LAS AGENCIAS DE CALIFICACIÓN

	EBITDA / Activos medios	EBITDA / Gastos de intereses	EBITDA de Margen	Margen operativo	(FFO + Intereses) / Intereses	FFO / Deuda	Cash Flow / Deuda neta	Deuda / EBITDA	Deuda / Valor contable	CAPEX / Depreciación	Volatilidad ingresos
Aaa	12.3%	11.5	30.6%	25.4%	17.2	41.5%	31.4%	1.9	31.5%	1.1	6.8
Aa	10.2%	13.9	19.5%	17.4%	15.2	43.4%	30.1%	1.8	31.0%	1.3	8.6
A	10.8%	10.7	15.8%	14.9%	13.1	34.1%	27.3%	2.3	40.7%	1.3	7.4
Baa	8.7%	6.3	13.9%	12.0%	8.1	27.1%	25.3%	2.9	46.4%	1.2	10.7
Ba	8.5%	3.7	13.3%	11.5%	5.1	19.9%	19.7%	3.7	55.7%	1.2	14.3
B	6.7%	1.9	11.2%	9.0%	2.9	11.7%	11.5%	5.2	65.8%	1.1	18.7
Caa-C	4.1%	0.7	7.0%	4.6%	1.6	4.6%	5.1%	8.1	89.3%	0.8	18.9

Tabla 3.1 Relación de algunas variables con los niveles de rating

Fuente: Moody's Financial Metrics para empresas globales no financieras (2017)

Es fácil comprobar que los valores medios acumulados de las frecuencias de fallidos son mayores en aquellas empresas que tenían unos *ratings* inferiores. Además, más de la mitad de las compañías que estaban en el nivel C de puntuación crediticia, quebraron en los diez años siguientes. En el otro extremo, las empresas que gozaban de la calificación máxima (Aaa), no tuvieron ningún problema de sucesos de crédito o financiero, incluso en períodos más largos. En la figura siguiente se muestran estas tendencias.




Figura 3.1 Frecuencias medias acumuladas de fallidos.

Fuente: Moody's Investor Service

III. LAS AGENCIAS DE CALIFICACIÓN

Las propias agencias de acreditación proporcionan estadísticas con las que se pueden medir los resultados históricos de las puntuaciones que otorgan a las empresas, observándose que, en grandes cifras, los resultados son adecuados. Lo que no es óbice para que se hayan producido sucesos muy llamativos en los mercados financieros que han puesto en tela de juicio la capacidad de las agencias para evaluar las emisiones de activos, las empresas e incluso las instituciones.

Con datos correspondientes a 2017, en el caso de empresas valoradas de nivel de inversión, por Moody's, el número de fallidos alcanzó 91 y el importe de deuda afectada fue de casi 80 mil millones de dólares, de los cuales más de 50 fueron en bonos y el resto en préstamos. Es una mejora sobre los dos años anteriores en los que estos fallidos superaban el centenar, con más de 136 mil millones de dólares de deuda afectada en 2016.

Los fallidos de 2017 se concentran en Norte América, en las dos terceras partes, afectando a la mitad de la suma total afectada, en Europa el 23%, y el resto en otras regiones.




Figura 3.2 Número de fallidos y volumen de deuda afectada entre 1970 y 2017

Fuente: Moody's Investor Service

Los sectores con las mayores tasas de fallidos son los relacionados con la industria forestal y productos derivados, y las del comercio al por menor

III. LAS AGENCIAS DE CALIFICACIÓN

INDUSTRY GROUP	DEFAULT RATE*	INDUSTRY GROUP	DEFAULT RATE*
Forest Product & Paper	8.99%	FIRE: Real State	0.49%
Retail	7.01%	Construction & Building	0.49%
Energy: Oil & Gas	6.09%	Capital Equipment	0.43%
Environmental Industries	5.56%	Banking	0.38%
Energy: Electricity	5.36%	Automotive	0.00%
Media: Broadcasting Subscription	3.74%	Beverage, Food, Tobacco	0.00%
Media: Diversified & Production	3.57%	Consumer goods: Durable	0.00%
Services: Business	3.09%	Consumer goods: Non-durable	0.00%
Wholesale	3.01%	Containers, Packaging, & Glass	0.00%
Transportation: Cargo	2.93%	FIRE: Insurance	0.00%
Aerospace & Defense	2.63%	Hotel, Gaming, & Leisure	0.00%
Metals & Mining	1.91%	Advertising, Printing & Publishing	0.00%
Telecommunications	1.61%	Sovereign & Public Finance	0.00%
High Tech Industries	1.28%	Transportation: Consumer	0.00%
Services: Consumer	1.18%	Utilities: Electric	0.00%
Chemicals, Plastics, Rubber	1.02%	Utilities: Oil Gas	0.00%
Healthcare Pharmaceuticals	0.62%	Utilities: Water	0.00%
FIRE: Finance	0.50%		

Tabla 3.2 Tasa de fallido a un año

Fuente: Moody's Investor Service

Aunque cabe preguntarse si existirían otras alternativas, se puede formular la pregunta si evaluaciones realizadas por agencias oficiales serían o no más fiables, y que incentivos tendrían estas agencias para mantener un alto nivel de calidad.

Desde luego, sin un nivel de responsabilidad personal e institucional, no cabe que ninguna organización o institución que tenga que emitir juicios o tomar decisiones sobre los resultados de éstos, podría considerarse que fuera de una calidad mínimamente aceptable.

3.2. Evolución histórica

A final del siglo XIX la economía norteamericana se había alzado a la primera posición de los distintos países del mundo, y su sistema financiero se desarrolló acordemente. Las emisiones de activos financieros se generalizaban, y las principales compañías se financiaban en este mercado, emitiendo acciones, bonos y pagarés. La bolsa de Nueva York se convirtió en la principal institución, y los bancos de inversión colocaban las emisiones de activos en los mercados. El público acudía a los mercados secundarios para realizar inversiones financieras, y las ganancias generalizadas incitaban a más personas a acudir a la bolsa para invertir sus excesos de liquidez, aunque la información a la que tenían acceso era, como es lógico, limitada, y, lo que es peor, sesgada.

Un suceso inesperado hizo, en 1907, que la bolsa perdiera más de la mitad de su valor. Fue la quiebra de Knickerbocker Trust Company, que se había financiado en los mercados, con la ayuda de la banca, emitiendo acciones y pagarés que no pudieron ser atendidos. La asimetría de la información disponible fue un hecho crucial que alertó a los inversores, ya que entregaban su dinero sin tener clara la situación financiera de las empresas. Se detectó, pues, una necesidad en los mercados: el disponer de información fiable proporcionada por instituciones independientes que compensasen la asimetría informativa existente en los mercados. Las agencias de *rating* surgieron para complementar esta demanda de los inversores.

Henry V. Poor publicó en 1860 un documento sobre los ferrocarriles y canales en los Estados Unidos, en los que se introduce el análisis de activos y de información en este sector. La firma Standard Statistics se creó en 1906 iniciando la evaluación de puntuaciones para las emisiones de obligaciones corporativas y de municipios, así como de deuda pública; esta compañía se fusionó en 1941 con Poor's Publishing, formando la actual S&P's, adquirida en su totalidad en 1966 por McGraw-Hill. En sus comienzos calificaba la deuda de más de siete mil municipios. El índice bursátil S&P500 es publicado por esta compañía y es uno de los principales indicadores económicos norteamericanos; se inició a partir de 233 empresas.

III. LAS AGENCIAS DE CALIFICACIÓN

J. Moody&Co empezó a publicar el manual de Moody's en 1900 con estadísticas e información sectorial de acciones y bonos, inicialmente en el sector de ferrocarril. Duró hasta la crisis de 1907 aunque se refundó en 1909, año en el que continuó con el manual de inversiones en el sector del ferrocarril, y en 1914 se crea Moody's Investors Service que calificaba los mercados de bonos gubernamentales. En 1962 fue adquirida por Dunn & BradStreet Co. En los setenta, se evaluaban activos de pagos y depósitos bancarios, incluyendo la duda comercial, cambiando a la financiación por parte de los emisores, y a su extensión internacional. A partir del año 2000 el accionariado se diversifica, incluyendo, entre otros a W. Buffet.

John K. Fitch fundó esta compañía editora en 1913, publicando estadísticas de bonos; ya en 1924 introduzco el sistema de calificación atribuyendo puntuaciones desde el nivel D hasta el AAA, hoy día globalmente adoptado, con ligeras modificaciones. Hoy día es filial del grupo de empresas francés Fimalac S.A., fundada en 1991, que también adquirió otras empresas de evaluación como Thomson BankWatch y Duff&Phelps Credit Rating, y que engloba actividades en el sector de servicios financieros, en actividades inmobiliarias y en inversiones. En 2006 entro en su capital la empresa de comunicación Hearst que años más tarde amplió su participación; y en 2006 adquirió una participación mayoritaria en la mayor agencia coreana, Corea Ratings.

En 1978 se crea la Inter Bank Company Analysis (IBCA), especializada en análisis de la solvencia de las entidades bancarias. Fue adquirida por Fitch en 1993.

Los análisis de las empresas ferroviarias de Estados Unidos se consideran el inicio de la publicación de información financiera sistemática para los inversores. Los bonos emitidos por los municipios norteamericanos fueron el siguiente sector analizado. Al surgir una crisis en los mercados, la demanda de información crece.

Hasta 1970 el sector se financiaba mediante los inversores, que demandaban las publicaciones de las agencias de calificación. Esto garantizaba la independencia de las opiniones y puntuaciones elaboradas por las agencias. Pero, el valor añadido para los

III. LAS AGENCIAS DE CALIFICACIÓN

emisores se puso cada vez más de manifiesto, pues unas puntuaciones elevadas facilitaban el acceso a los mercados de capital, disminuía los diferenciales a pagar, y, en definitiva, disminuían los costes de financiación por parte de las empresas e instituciones. A su vez, el análisis de cada activo o empresa aumentaba en complejidad. El modelo de financiación de los informes de calificación cambió en poco tiempo; las agencias cobraban a los emisores por la elaboración de los *ratings* correspondientes a sus emisiones o a las propias empresas, las cuales se convertían en clientes de sus evaluadores. La posibilidad de conflictos de interés es evidente. Y así lo especificaba, en 1957, el vicepresidente de Moody's en el periódico *The Christian Science Monitor* de Boston, al indicar que era evidente que no se podía cobrar por emitir un *rating* sobre un bono, pues querría decir que las calificaciones era un bien al que se le puede poner precio.

La quiebra de Penn Central de Filadelfia (creada mediante la fusión de varias compañías ferroviarias de Pensilvania y Nueva York, en 1968) acaecida en 1970, y que constituye la mayor quiebra financiera de los Estados Unidos. Casualmente el actual presidente norteamericano adquirió la zona comercial de esta compañía en Manhattan. La influencia de esta quiebra fue la restricción del crédito bancario con el riesgo de recesión.

Pero todavía otras circunstancias influyeron en este sistema de financiación: los requisitos regulatorios. En estos años el organismo regulador norteamericano, la Securities and Exchange Commission (SEC), empezó a establecer requisitos de liquidez a la banca y otros agentes de los mercados, y exigió que algunas agencias reconocidas puntuaran las emisiones e instituciones.

Esto originó que las empresas tuvieran que acudir a las agencias de calificación para obtener estas valoraciones que les permitiesen introducir sus emisiones en los mercados.

En 1975 la SEC usaba las calificaciones para determinar las reservas que deberían tener algunas compañías, y evitar problemas como los de la Penn. Los *ratings* más bajos

III. LAS AGENCIAS DE CALIFICACIÓN

originaban la necesidad de disponer de mayores reservas. Para evitar el monopolio de las tres grandes agencias, se creó la National Recognized Statistical Rating Organisation (NRSRO) que incluía diez agencias calificadoras, entre las que estaban las tres grandes. Esta organización suponía un oligopolio de hecho, ya que muchos fondos y sociedades de inversión solo podían invertir en activos calificados positivamente por las agencias del NRSRO que inicialmente fueron solo las tres grandes, lo que provocó un crecimiento espectacular de las agencias de calificación con el nuevo modelo de financiación en base a los emisores.

Las agencias calculan las calificaciones actualmente, bajo demanda de los emisores, aunque, en algún caso, emiten estas calificaciones sin tener una solicitud el emisor.

Los emisores buscan obtener calificaciones altas por las agencias de valoración, que avalen tanto el nivel de solvencia de la empresa como de los activos emitidos. La SEC (y el regulador español) exigen que la emisión de obligaciones o de bonos, debe estar calificada por alguna agencia reconocida.

Los inversores, fundamentalmente los fondos de pensiones, las aseguradoras y los fondos de inversión usan las calificaciones de los activos para analizar los riesgos de sus inversiones; incluso, muchas de estas instituciones, en sus estatutos, exigen que los fondos solo se apliquen a activos que superen un cierto nivel de *rating*. Otra función que se atribuye a las calificaciones es que permiten la comparabilidad de los riesgos asociados a alternativas de inversión, o a los actores involucrados.

Los vendedores de activos, como los bancos de inversión o los intermediarios financieros, utilizan los *ratings* como garantía de solvencia de los productos que venden. Por ejemplo en los fondos de titulización, los diferentes tramos ofertados se valoran en función de los *ratings* de los activos que los componen.

Los reguladores usan las calificaciones crediticias en su normativa. El volumen de las reservas de capital bancaria se calculan en función de la calificación de los activos emitidos; en las aseguradoras, la influencia de los *ratings* en la determinación de las reservas técnicas se basa en la calificación de su cartera de inversión.

En definitiva, los informes de calificación de crédito emitidos por las agencias se pueden considerar desde dos puntos de vista:

- Las agencias de certificación afirman en sus documentos que los informes de calificación de riesgo son solo opiniones condicionadas a la información que han recibido (generalmente desde las propias empresas calificadas), sin que deban considerarse recomendaciones de inversión, ni sin que las agencias asuman responsabilidad alguna por estas opiniones.

- Los demás agentes del mercado, incluyendo los reguladores, las han convertido en oráculos a los que hay que seguir sin que quepa la posibilidad de duda, y en requisitos legales para muchas operaciones financieras.

Y todo ello a pesar que las propias agencias dejan meridianamente claro que proporcionan opiniones y nunca recomendaciones de inversión. Incluso alguna está dada de alta como un editor de prensa, y sus publicaciones son subjetivas.

3.3. Puntuaciones elaboradas por las agencias

Las distintas empresas de evaluación disponen de equipos de expertos financieros, y aducen que las puntuaciones no se obtienen simplemente aplicando unos algoritmos. Básicamente una puntuación o *rating* de un producto o institución se obtiene mediante dos tipos de información; una denominada 'cuantitativa' y otra 'cualitativa'.

Los métodos cualitativos se basan en decisiones de consenso de estos grupos de expertos sobre que variables usar y que ponderaciones atribuir a cada una. En operaciones crediticias no es necesario disponer de un amplio historial pasado de

operaciones similares, aunque, sí se puede usar éste. En los métodos cuantitativos si se usan bases de datos de información sobre las que se elaboran los modelos cuyo objetivo es que las empresas u operaciones menos solventes reciban puntuaciones bajas, y las más solventes, puntuaciones altas. Este es el enfoque que se ha utilizado en este trabajo: se reproduce con bastante precisión los *ratings* de empresas a partir de información pública disponible.

Lógicamente, los modelos empleados son específicos para cada sector económico, o para cada tipo de operación. No es lo mismo puntuar a una empresa una emisión de obligaciones o un productor financiero estructurado. Las grandes agencias publican parcialmente la información para evaluar a las empresas, dentro de su enfoque cuantitativo, siendo más opacas en los algoritmos cualitativos empleados. Esto es lógico, pues este acervo de conocimientos y la forma de tratar la información constituyen el principal activo de las agencias de calificación, y, consecuentemente, no lo hacen público.

Las fases en las que se elaboran los *ratings* son similares en las distintas agencias:

1. Solicitud del emisor de un activo para su calificación
2. Evaluación inicial por un grupo de expertos de la agencia
3. Reunión con los gestores del emisor para analizar la evaluación inicial
4. Análisis de la emisión y propuesta de un *rating* al comité
5. Revisión por el comité de *rating* y votación de la propuesta del analista
6. Notificación al emisor con la justificación del *rating* asignado
7. Publicación del resultado en el web de la agencia y en la prensa
8. Vigilancia y seguimiento (tras lo que puede volver al comité de *rating*) con las propuestas de modificación del *rating* inicial.

III. LAS AGENCIAS DE CALIFICACIÓN

Posteriormente, las agencias como S&P's realizan estudios para medir la precisión de sus puntuaciones, incorporando las transiciones a otros niveles de *rating* a lo largo del tiempo. Estos análisis se usan para reformar los métodos de asignación de puntuaciones y para informar a los inversores de la volatilidad en los *ratings* de una emisión o de una institución.

Fitch (2018) informa sobre los parámetros y magnitudes públicas que usa en sus evaluaciones, en la parte cuantitativa.

Las tres grandes agencias de calificación, S&P's, Moody's y Fitch realizan la mayor parte de los informes de evaluación en el mundo. Los resultados los presentan con una escala ordenada en la que informan sobre la probabilidad de incumplimiento de las obligaciones financieras. Los resultados de estas tres compañías son similares, aunque no coincidentes en muchos casos, con respecto a la calificación otorgada. Se basan en series de caracteres, cuyo resumen se puede representar en la siguiente tabla

	Estimación de la capacidad	S&P's	Moody's	Fitch
Grupo con capacidad para atender sus obligaciones	Extremadamente alta	AAA	Aaa	AAA
	Muy alta	AA	Aa	AA
	Alta	A	A	A
	Adecuada	BBB	Baa	BBB
Grupo con riesgo de no poder atender sus obligaciones (not prime)	Menos vulnerable	BB	Ba	BB
	Más vulnerable	B	B	B
	Vulnerable	CCC	Caa	CCC
	Muy vulnerable	CC		CC
	Sin capacidad	SD/D	D	D

Tabla 3.3 Escala de calificación crediticia a largo plazo

Fuente: Moody's y S&P's

Las probabilidades de fallido (PD) en un período de cinco años, para las cuatro primeras categorías son, respectivamente, 1/600, 1/300, 1/150 y 1/30; para los grupos BB y B,

III. LAS AGENCIAS DE CALIFICACIÓN

1/10 y 1/5; en el caso CCC, se estima en 1/2, y superior para las restantes. S&P's y Fitch emplean diez categorías 'prime'; desde AAA hasta BBB- o Baa3, respectivamente. En el caso de 'not prime' S&P's usa trece categorías, empezando por BB+; Moody's dispone de doce calificaciones, desde Ba1 hasta -; Fitch usa once niveles. La inclusión de un signo positivo o negativo adicional es un aviso de posible desplazamiento en la calificación.

Las calificaciones de las dos principales agencias de clasificación se muestran en la siguiente tabla

S&P's	Moody's	S&P's	Moody's
AAA	Aaa	Estable	Prime1
AA+	Aa1	Estable	Prime1
AA	Aa2	Estable	Prime1
AA-	Aa3	Prime	Prime1
A+	A1	Prime	Prime1
A	A2	Prime	Prime12
A-	A3	Prime	Prime12
BBB+	Baa1	Prime	Prime2
BBB	Baa2	Prime	Prime23
BBB-	Baa3	Prime	Prime3
BB+	Ba1	No prime	No prime
BB	Ba2	No prime	No prime
BB-	Ba3	No prime	No prime
B+	B1	No prime	No prime
B	B2	No prime	No prime
B-	B3	No prime	No prime
CCC+	Caa1	No prime	No prime
CCC	Caa2	No prime	No prime
CCC-	Caa3	No prime	No prime
D	Ca	No prime	No prime

Tabla 3.4 Escala de calificación crediticia a largo plazo

Fuente: Moody's y S&P's

III. LAS AGENCIAS DE CALIFICACIÓN

Las categorías 'prime' o grado de inversión son calificaciones de empresas con perspectivas favorables para atender sus obligaciones crediticias, mientras que las 'no prime' engloban a las compañías en riesgo de incumplimiento.

A corto plazo, los grados son distintos, aunque el objetivo actual es la predicción de las calificaciones a largo plazo.

En la evaluación de los *ratings* asignados para las empresas, es necesario tener en cuenta la asimetría adicional en los resultados debido a que la mayor parte de los ingresos de las agencias provienen de los contratos de evaluación entre las agencias y las propias compañías que son evaluadas. Los emisores de activos y las empresas eligen libremente las agencias de acreditación que les van a evaluar, por lo que siempre puede existir la sospecha que aquellas agencias que asignen puntuaciones más elevadas tendrán prioridad a la hora de ser elegidas. Los incentivos son muy fuertes; por ejemplo, en una emisión de activos, los diferenciales serán mayores para las compañías o para las emisiones con menor calificación crediticia, y, recíprocamente, inferiores, en el caso de tener una calificación alta. Además el acceso a los mercados financieros es más fácil (y barato) para aquellas empresas con mejor calificación crediticia. Por lo tanto, al seleccionar una agencia de acreditación, aquellas que tienda a mayores niveles de inflación de *ratings*, tendrá más posibilidades de ser elegida.

Hay que tener en cuenta que, si se rebaja la cualificación de una empresa, rebajando su credibilidad crediticia, esto se puede convertir en una autopredicción, por sus efectos en los mercados. Esto origina una cierta resistencia en las agencias para proceder a rebajar el *rating* de una compañía, lo que puede originar situaciones de riesgos ocultos. Así, cuando se produjo el fallido de Enron en 2002, las tres grandes agencias le tenían calificada en las categorías de inversión, y la reacción de las agencias fue tardía, originándose el escándalo en los mercados. Más adelante, cuando la crisis financiera de 2008 comenzó, más de la mitad de los productos que tuvieron problemas estaban evaluados en los niveles máximos del grado de inversión. Estos hechos originaron la polémica subsiguiente sobre la forma de funcionamiento de las agencias de *rating*, que no se anticiparon a los sucesos que estaban a punto de ocurrir. Las críticas se unieron a la dificultad de evaluar los productos financieros derivados y estructurados, para los que

no existían modelos adecuados de valoración del riesgo. Muchos de estos productos se habían emitido por entidades cuyos intereses estaban relacionados con las entidades que los colocaban en los mercados secundarios. Estos riesgos relacionados no habían sido tenidos en cuenta a la hora de evaluar el riesgo conjunto de una serie de productos que provocaron unos fallidos conjuntos, y que dejaron expuestas a empresas de las más importantes en el mundo, como por ejemplo, la aseguradora AIG, que tuvo que ser rescatada por el gobierno norteamericano.

A partir de estos hechos, la credibilidad de las agencias cayó, y se inició un proceso regulatorio en los Estados Unidos y en Europa, así como en otros países desarrollados. Las críticas sobre S&P's, Moody's y Fitch arreciaron, incluso tratándose de crear empresas públicas de *rating*, aunque es dudoso que ninguna empresa evaluadora pudiera hacerse responsable de los fallos que se pueden producir en sus puntuaciones (las cuales, en su inmensa mayoría son correctas y fiables). Al menos, la supervivencia de estas agencias está ligada a mantener un nivel de reputación adecuado, lo que no sería el caso de unas agencias públicas, y esto es la mejor (y quizás única) garantía que en el futuro los *ratings* irán siendo cada vez más precisos. Aunque, en el último capítulo de esta memoria se apunta a una cierta convergencia entre los *ratings* de S&P's y Moody's, lo que origina inquietudes sobre la extensión de la teoría de los 'riesgos correlacionados' a las agencias de acreditación.

3.4. Normativa regulatoria

El cambio más importante en la evolución de las agencias se produjo cuando, en 1975, el regulador norteamericano, la SEC, empezó a usar las puntuaciones para determinar el capital que deberían mantener los actores del mercado. En una emisión de un activo con puntuaciones altas, los requerimientos de capital para los intermediarios eran menor que si el activo era de mayor riesgo, en cuyo caso se requería un mayor nivel de fondos propios. Esto aumentó la importancia de las calificaciones, pero también fue preciso regular quienes podrían actuar como agencias de calificación. Así la SEC le otorgó la calificación de agencias de *rating* reconocidas (NRSRO, por sus siglas inglesas. Nationally Recognized Statistical Rating Organizations) a las tres agencias mayores: S&P's, Moody's y Fitch.

III. LAS AGENCIAS DE CALIFICACIÓN

Los *ratings* se hicieron omnipresentes en los mercados financieros: muchos prestamistas incorporaron condiciones sobre los niveles de acreditación en emisiones de activos, incluso estipulando que una disminución de la puntuación podría acelerar la devolución del capital, las condiciones del préstamo, incluyendo las garantías asociadas a éste.

Para calibrar la importancia de estos cambios, basta considerar las pérdidas de 115 millones de euros que sufrió hace unos años la Junta de Andalucía, en tres operaciones en yenes japoneses; en 2012, Moody's rebajó la calificación de solvencia de Andalucía a Ba2 lo que obligó a devolver anticipadamente las emisiones de 2009-10 de más de 252 millones de euros (en yenes), que tuvo que devolver en 2012-13 con un coste superior a 367 millones de euros (por la apreciación del yen frente al euro). El 14 de abril de 2009 se publicó en el BOJA el decreto 79/2009 autorizando la emisión de un programa de Euro Medium Term Notes a devolver en 30 años, que resultó catastrófico, pues, aunque se hubo previsto contrarrestar este riesgo con un producto de cobertura (un Credit Default Swap, CDS) que aumentaba el coste de la operación del 3.17% al 6.1051%; y así para las otras operaciones. Pero no se tuvo en cuenta la cláusula de devolución anticipada (*rating trigger*) en caso de disminución en la calificación lo que ocurrió en octubre de 2012; de esta forma el CDS dejó de ser efectivo y además de devolver anticipadamente los yenes al acreedor con una gran pérdida, se incurrió en otra pérdida de comisiones de cancelación de los CDS.

La regulación norteamericana aumentó a un ritmo casi exponencial. Los fondos de bajo riesgo dirigieron más del 95% de sus inversiones a emisiones calificadas de nivel de inversión. Pero lo que estaba ocurriendo ante esta maraña normativa es que los fondos de inversión estaban trasladando la gestión del riesgo a las agencias de calificación (las cuales, recuérdese, que seguían manifestando que sus puntuaciones eran meras opiniones y en ningún caso recomendaciones de inversión). Era más cómodo para los gestores de fondos considerar como realidad lo que eran opiniones, y, más arriesgado, a nivel profesional, realizar su trabajo de evaluar el riesgo de las operaciones financieras, trabajo por el que eran remunerados. Es decir, no solo se trasladaba a terceros (las

III. LAS AGENCIAS DE CALIFICACIÓN

agencias) el análisis del riesgo, sino también la responsabilidad profesional ante posibles fallidos o malas decisiones de inversión.

Los resultados de las agencias son generalmente buenos. Existen trabajos de seguimiento de fallidos en relación a las puntuaciones. La agencia S&P's a través de un documento de trabajo (Macdonald et al 2014) publica resultados agregados sobre largos períodos de tiempo. Así se tiene una estructura de fallidos que muestra que estos son menos frecuentes cuando gozan de *ratings* más altos.

Issue Defaults By Initial Rating					
Initial rating	Number	% of total	Defaults	% of defaults	% chance of default
AAA	0	0.00	0	0.00	0.00
AA	1	0.17	0	0.00	0.00
A	51	8.90	1	2.56	1.96
BBB	334	58.29	13	33.33	3.89
BB	114	19.90	14	35.90	12.28
B	63	10.99	10	25.64	15.87
CCC/C	10	1.75	1	2.56	10.00
Category					
Investment grade	386	67.36	14	35.90	3.63
Non-investment grade	187	32.64	25	64.10	13.37
Total	573	100.00	39	100.00	6.81

Tabla 3.5 Estadísticas de fallidos en función del *rating* original

Fuente: S&P's RatingDirect

En relación a la puntuación original, los fallidos están relacionados con calificaciones que han sido modificadas a la baja.

Esto no es óbice para resaltar que las agencias no detectaron situaciones muy claras que originaron una pérdida de confianza en sus calificaciones. No detectaron la quiebra del condado de Orange en California, las crisis financieras en el sudeste asiático y en Rusia, además de la caída citada de la firma ferroviaria Penn Central, o del fondo Long-Term Capital Management, en los noventa, o la crisis de Enron, cuyos altos *ratings* fueron

III. LAS AGENCIAS DE CALIFICACIÓN

mantenidos hasta cuatro días antes de su caída en 2001. Ya en el pasado se habían producido situaciones dramáticas: casi el 80% de los bonos municipales que en 1929 tenían calificación AA o AAA resultaron fallidos durante la crisis de los treinta.

Project Finance Rating Changes By Category				
Original rating	Upgrades	Downgrades	Unchanged	Defaults
AA	0	1	0	0
A	1	15	34	1
BBB	16	75	230	13
BB	12	21	68	14
B	7	6	40	10
CCC/C	3	0	5	1
Category				
Investment grade	17	91	264	14
Non-investment grade	22	27	113	25
Total	39	118	377	39

Tabla 3.6 Estadísticas de los cambios en el *rating*

Fuente: S&P's RatingDirect

Moody's ha tenido una cultura más próxima a los ambientes académicos, con lo que se han distinguido durante muchos años por tener una actitud crítica respecto a la inflación de puntuaciones. En un artículo titulado 'Why everyone hates Moody's', citado por Mc Lean y Nocera (2010), y publicado en la revista *Treasury and Risk Management*, en la que los casi cien directores financieros de las correspondientes empresas confirmaron esta actitud de la agencia. Ya en los noventa se rechazó la evaluación de un conocido producto estructurado en función que podría tener una calificación inferior a lo esperado por el emisor. Todavía en la actualidad, como se verá, comprobamos que Moody's es más estricta que S&P's en la asignación de puntuaciones. Sin embargo, la generalización de emisiones de productos estructurados y su calificación y la política de gestión de la compañía con sus directivos compensándoles en función de los beneficios generados, vino a aproximar el enfoque de Moody's aproximándolo al de otras agencias. La nueva dirección de su división de productos estructurados se lanzó en la calificación

III. LAS AGENCIAS DE CALIFICACIÓN

de productos basados en carteras hipotecarias no fue muy afortunada, al tender a proporcionar a los emisores las calificaciones que esperaban, y a presionar a sus propios analistas a actuar en esta línea. Los emisores se internaron en los ellos mismos denominaron '*rating shopping*', es decir, en usar las puntuaciones más favorables de una agencia a productos similares para presionar al alza a sus propias calificaciones.

El aumento de la competencia entre las agencias calificadoras no produjo el efecto de mejorar el producto, acrecentando la calidad de las puntuaciones, sino que originó el efecto contrario: la inflación en los *ratings*. Es decir, en la pérdida de fiabilidad en las opiniones proporcionadas por las agencias. No solo fue el fracaso en anticipar la caída de Enron hasta unos días antes de producirse, sino que otros escándalos similares fueron los de WorldCom y de Tyco, entre otros. En las investigaciones posteriores, en S&P's se reconoció no haber leído los datos contables de Enron.

Para evitar una regulación más estricta, Moody's adoptó un código interno de conducta, rechazando que las relaciones comerciales con sus clientes no afectarían a sus *ratings*, los cuales se basarían solo en factores importantes y objetivos. Sin embargo, tanto en S&P's o en Moody's no hicieron cambiar los procesos internos en éstas, ni se adoptaron acciones contra los responsables.

A principios de siglo se extendieron unos productos financieros que se extendieron en el mercado, sin que se pudiese determinar exactamente el nivel de riesgo que acarrearían: los bonos con garantías de deudas, o '*Collateralized Debt Obligations*' (CDO); cualquier producto que generase rendimientos se incluían en la cesta de garantías de una CDO, y no solo como en los bonos hipotecarios; las entidades financieras pudieron trasladar sus activos más arriesgados y de menor calidad a estas carteras de titulización. Estas garantías se dividían en tramos que eran puntuados por las agencias, que asignaban generalmente una puntuación máxima al tramo superior que suponía una parte importante del producto, seguida de otro tramo puntuado como válido para inversión; para incentivar la inversión en CDOs, se añadía un tramo de garantías que no era sujeto a *rating*, pero que era el último a percibir dividendos. Además, a menudo no se

III. LAS AGENCIAS DE CALIFICACIÓN

proporcionaba información sobre los activos en cada tramo, o sus cambios. Los gestores de los CDOs percibían comisiones sobre el volumen vendido, así como las empresas financieras que los colocaban, y, como no, las agencias de *rating*. Los inversores se fiaban en la calificación, sin saber realmente cual era la garantía real de los CDOs en los que invertían, aunque muchas de estas garantías tenían a su vez una calificación inferior a la del tramo en el que estaban incluidas. La incorporación de garantías basadas en préstamos hipotecarios aumentó la confianza de estos inversores, además de proporcionar rendimientos mayores (lo que muestra que los gestores y promotores de estos productos reconocían implícitamente el mayor riesgo asociado a las garantías hipotecarias). A su vez, en estos tramos se incorporaron como garantías tramos de CDO's de categorías intermedias o bajas, que se calificaban como excelentes en el producto final. Las ventas de estos productos alcanzaron medio billón de dólares en 2006. Las agencias de calificación habían emitido puntuaciones AAA para productos financieros de alto riesgo, y, lo que es peor, sin poder realmente valorar el riesgo real asociado a las garantías de los distintos tramos. La caída de los tipos de interés, a comienzos de siglo, propició el aumento de la demanda en el sector inmobiliario, y el inicio de esta cadena de titulizaciones y de generación de productos estructurados.

Existen serias dudas sobre la capacidad de las agencias para proporcionar opiniones fiables sobre la economía o sobre la salud financiera. Incluso sobre la disponibilidad de un poder de influencia que pueden contribuir a iniciar tendencias negativas. Algunos autores indican que incluso contribuyeron a exacerbar la crisis global de hace más de una década, pero que no existe voluntad política de regularlas; todo ello se confirma por los requisitos legales de disponer de *ratings* en muchas circunstancias.

Entre los fallos más recientes de anticipar las caídas del mercado destaca el de Enron, una de las grandes compañías norteamericanas creada en 1985 a través de la fusión de la Houston Natural Gas Co. y la InterNorth Inc. reconvertida en un intermediario en el mercado energético, además de un suministrador. Una medida polémica, pero sin embargo aprobada por la SEC, fue el cambio de los sistemas contables al denominado '*mark-to-market*', que permitía valorar activos y pasivos por lo que se llamaba '*fair value*' en lugar del precio de coste; esto permitió una manipulación fraudulenta de los

III. LAS AGENCIAS DE CALIFICACIÓN

estados contables; por ejemplo, si se construía una planta de generación, los beneficios esperados para el futuro se contabilizaban como beneficios actuales; si la planta originaba pérdidas, se transfería el activo fuera del balance, con lo cual las pérdidas no afloraban. Los activos que originaban pérdidas y éstas se trasladaban a unos estados extra-contables denominados '*special purposes vehicles*' (SPV); a éstos se transferían acciones, cuando subían, a cambio de efectivos, y anotaba estos SPV como contrapartida garantizando un activo del balance de Enron, con lo que daba la apariencia de existencia de colateral sólido para estas operaciones; aunque, al ser la garantía las propias acciones de Enron, una bajada de la cotización de la compañía hacía que desapareciesen la garantía, como así ocurrió. Además creó una plataforma de comercio de diversos productos en las que Enron actuaba como contraparte en todas las transacciones. Fue calificada como la compañía más innovadora de Estados Unidos durante seis años seguidos; el último, 2001, es decir uno antes de su quiebra; Fortune tampoco anticipó lo que venía, aunque la cotización de la acción había caído.



Gráfico 3.1 Evolución de la cotización en Enron y eventos asociados a la empresa

Fuente: <https://www.famous-trials.com/enron/1791-stockchart>

En el gráfico se muestran varios hitos de la compañía: A. Nombrada compañía más innovadora por Fortune en 2001; B. Los directivos de Enron reciben 1100 millones de dólares por la venta de sus acciones (es claro que sabían lo que vendría después); C. En abril proporciona un informe financiero indicando beneficios de 536 millones de dólares; D. Dimisión del gerente por 'motivos personales'; E. El presidente de la

III. LAS AGENCIAS DE CALIFICACIÓN

compañía vende 93000 acciones pero a la vez recomienda a los empleados de Enron que compren; desde agosto había vendido más de novecientas mil acciones; F. De nuevo el presidente recomienda comprar a los empleados garantizando sus sistemas contables; G. En octubre, en el informe financiero anuncia 618 millones de pérdidas; H. Unos días después, la SEC inicia una investigación sobre la contabilidad de la compañía; I. A principios de diciembre, se declara en quiebra. Su cotización había bajado desde más de 90 \$ por acción a prácticamente 0. En marzo anterior ya se había publicado un artículo en la propia revista Fortune cuestionando la cotización de Enron. La auditora Arthur Andersen fue condenada por obstrucción a la justicia por destrucción de documentación de la compañía. Los 85000 empleados de Enron perdieron su trabajo, y muchos de ellos sus fondos de pensiones invertidos en acciones de la compañía.

Hasta el 30 de octubre de 2001 no se disminuyó el *rating* de Enron. Tampoco el auditor Arthur Andersen puso objeciones a los SPV de ocultar pérdidas ni al riesgo implícito de este sistema extra-contable.

La quiebra de WorldCom, la segunda empresa de telefonía norteamericana también estuvo asociada a la ocultación de gastos, aunque era esperada desde 1999 con la disminución de pedidos y servicios por parte de las empresas de tecnologías de la información. Le había además concedido préstamos de 366 millones a su presidente. En los 90 había adquirido varias empresas de comunicaciones como MCI, pero su deuda había crecido hasta 41000 millones de dólares. Para ocultar la caída en sus beneficios se adjudicaron 3850 millones de dólares de gastos corrientes como inversiones, lo que permitía imputar estos gastos en varios ejercicios, en lugar de en el año en que se han producido, apareciendo un aparente beneficio contable de unos 1400 millones de euros en 2002, en lugar de mostrar la situación real de pérdidas. De nuevo el auditor Arthur Andersen (que fue cambiado a KPMG) ocultó informes de algunos directivos que indicaban que se estaban cometiendo irregularidades contables. También se registraban ventas varias veces. La cotización de la compañía cayó de forma estrepitosa. Las pérdidas afectaron a varios bancos, fondos de inversión y accionistas, además de a 45000 empleados despedidos y a proveedores entre los que causaron quiebras

III. LAS AGENCIAS DE CALIFICACIÓN

inducidas. La disminución del *rating* de S&P's fue realizada en junio de 2002, desde B+ a CCC-; Moody's hizo lo propio dos días antes, desde B1 a Ba2, y luego a Ba3.

En ambos casos las agencias de *rating* no anticiparon el problema. La rebaja de *rating* en el grado de inversión a de no inversión (*'junk bonds'*) se produjo 4 días antes de quebrar, en el caso de Enron, y 3 meses antes en WorldCom. Está claro que los *ratings* no son predicciones, sino que son arrastrados por la realidad del mercado.

En 2002 se publicó la ley *Sarbanes-Oxey Act* (SOX) que imponía nuevas regulaciones contables y financieras. Como consecuencia, la SEC emitió un informe en 2003 sobre los procedimientos para ser acreditadas como NRSRO una agencia, generando la ley de *Credit Rating Agency Reform Act* (CRARA) de 2006, en la que se especificaban los criterios y plazos del proceso de acreditación, y con el objetivo de aumentar la competencia entre las agencias. También la SEC reguló la publicidad de la información de las empresas cotizadas en bolsa a analistas e inversores, aunque estableció una excepción para las agencias de *rating*, pero no a los consultores de inversiones.

En 2010, ya en plena crisis financiera se publicó la ley denominada *Dodd-Frank Act* que eliminó esta excepción sobre la transmisión de información, pero mantuvo la exención de responsabilidad de las agencias por sus informes. Esto no iba a conseguir incrementar la fiabilidad de los *ratings*.

En la crisis financiera de 2008, activos basados en garantías hipotecarias (MBS o *Mortgage Baked Securities*) valorados en cientos de miles de millones de dólares y que gozaban de la máxima calificación (AAA) fueron recalificados como bonos basura. El 73% de los 0.8 billones de dólares calificados por Moody's en la máxima categoría, dos años después estaban calificados en categorías de no inversión. El informe sobre la investigación de la crisis financiera en los Estados Unidos (2011) consideró evitable la crisis, indicando que los gestores y supervisores ignoraron las señales de aviso, y no indagaron o comprendieron el nivel de riesgo en el que se estaba incurriendo. Se incrementó enormemente el crédito con insuficientes garantías (*subprime*), la

III. LAS AGENCIAS DE CALIFICACIÓN

titulización de estos bonos hipotecarios que originaban carteras con bonos de distinta calidad y sin que se supiese realmente quien era el deudor final, el incremento de los precios inmobiliarios que forzosamente debía detenerse, las políticas de préstamos en los que se refinanciaban hipotecas anteriores para obtener liquidez y capacidad de gasto adicional, los productos derivados no regulados, y otros factores observables. Una parte de la culpa se atribuye a la falta de intervención en los préstamos hipotecarios por parte de la Reserva Federal. Las instituciones financieras crearon, compraron y vendieron títulos sin valorarlos, y financiaban diariamente cantidades ingentes de tesorería con garantías de bonos hipotecarios 'basura'. Y finalmente, las principales empresas e inversores confiaban en las evaluaciones de riesgo establecidas por las agencias de *rating*, aunque en el informe de la citada comisión, no consideraron significativa su influencia en la crisis. Como botón de muestra, se duplicó la proporción de fallidos en los créditos hipotecarios a partir de 2006 en los meses siguientes a la concesión de los respectivos préstamos.

La circulación monetaria se aceleró; los bajos tipos de interés y los inversores de todo el mundo contribuyeron a la expansión. Numerosos sectores estaban obteniendo beneficios: la industria de la construcción, la inmobiliaria, los intermediarios financieros que lanzaban los préstamos, los bancos de inversión, los agentes de la banca y de las finanzas. Los préstamos obtenidos con garantía hipotecaria sirvieron para gastos ordinarios de las familias, e incluso para inversiones, vehículos, vacaciones o financiar gastos a su vez cargados a tarjetas de crédito. Todo dependía en que el precio de la vivienda siguiera subiendo y que los prestatarios pudieran atender las anualidades hipotecarias. Obviamente este proceso piramidal no podía mantenerse indefinidamente.

Al formalizarse un préstamo hipotecario, se transferían a fondos de titulización y a bancos de inversión, como Lehman Brothers o Bear Stearns y otros, e incluso a bancos comerciales como Citibank, Wells Fargo,... Estos activos generaban bonos de titulización que eran calificados como AAA por las agencias, pues el hecho que estuvieran respaldados con la garantía real asociada a una hipoteca les daba apariencia de seguridad. Pero no eran las hipotecas habituales en el mercado norteamericano, que financiaban el 80% del valor real de la propiedad a treinta años, sino hipotecas otorgadas en muchas ocasiones a prestatarios que a la larga no podían responsabilizarse de los préstamos hipotecarios si no es refinanciándolos con otros préstamos superiores.

III. LAS AGENCIAS DE CALIFICACIÓN

A veces estos activos fueron incluidos en los CDOs (Collateralized Debt Obligations) que a menudo contenían la parte menos fiable de estos activos, y que a su vez eran vendidos a otros inversores, de nuevo con la máxima puntuación proporcionada por las agencias. Incluso muchos inversores compraron otros productos de aseguramiento como los CDS (*Credit Default Swaps*) para protegerse. Nuevos CDOs fueron generados a base de los originales. Incluso se crearon los llamados CDOs sintéticos, en los que los componentes eran opciones sobre productos hipotecarios. Así se fueron creando diversos niveles de estructuración, con nuevos inversores, y nuevos intermediarios. Un préstamo original podía formar parte de muchos activos financieros o incluso de opciones sobre estos, adquiridos por cientos de inversores. En 2003 Bear Stearns creó un fondo con una inversión mínima y un apalancamiento de 10 a 1 para adquirir CDOs con unas comisiones de gestión superiores al 20%, pero con una rentabilidad para los inversores del 17% el primer año y 10% el segundo. En 2006 creó otro fondo con un apalancamiento mayor, y consiguió 18000 millones de dólares de los inversores. Se necesitaban más préstamos hipotecarios para obtener rentabilidad, con lo que se promovió masivamente la compra de casas o la refinanciación de préstamos; todo ello en la creencia que el mercado inmobiliario iba seguir al alza indefinidamente. Los reguladores no querían ver la tormenta que se avecinaba, y que ya se había producido unos años antes en varias ciudades norteamericanas. Varias compañías refinanciaban préstamos de forma fraudulenta, y con tipos de interés mucho más elevados, con tomadores que claramente no podría hacer frente a las anualidades. Estos créditos dudosos (subprime) fueron creciendo a 730000 millones de dólares en 2004, y más de un 30% adicional al año siguiente.

Algunas voces se alzaron previniendo la catástrofe financiera inminente; en una reunión, a mediados de 2005 de los principales banqueros centrales del mundo (B. Bernanke y A. Greenspan de la Reserva Federal, J.C. Trichet, del BCE, M. King, del Banco de Inglaterra, entre otros). R. Rajan que había sido economista jefe del FMI presentó un trabajo sobre el riesgo de los nuevos productos financieros, y que los procedimientos de inversión basado en algunos productos estructurados podría provocar una catástrofe, si el sistema entraba en crisis. Sin éxito; incluso fue denostado por el entonces rector de la universidad de Harvard, tachándolo de contrario al cambio tecnológico. Otros economistas recibieron el mismo trato, advirtiéndoles que los *ratings*

III. LAS AGENCIAS DE CALIFICACIÓN

AAA no eran realistas. Aunque el mercado inmobiliario entró en una fase descendente en 2006, la demanda de activos hipotecarios para su titulización siguió robusta. Pero a final de año se inició la caída, y aumentó el número de impagos de préstamos. Las compañías asociadas al gobierno (GSE) Fannie Mae y Freddie Mac son dos grandes empresas públicas que actuaban en los mercados hipotecarios para proporcionarles liquidez y abaratar el coste de los préstamos, comprando estos activos hipotecarios para titularizarlos y venderlos a inversores, añadiéndoles unas garantías adicionales. El funcionamiento de estas empresas se resume en el esquema siguiente

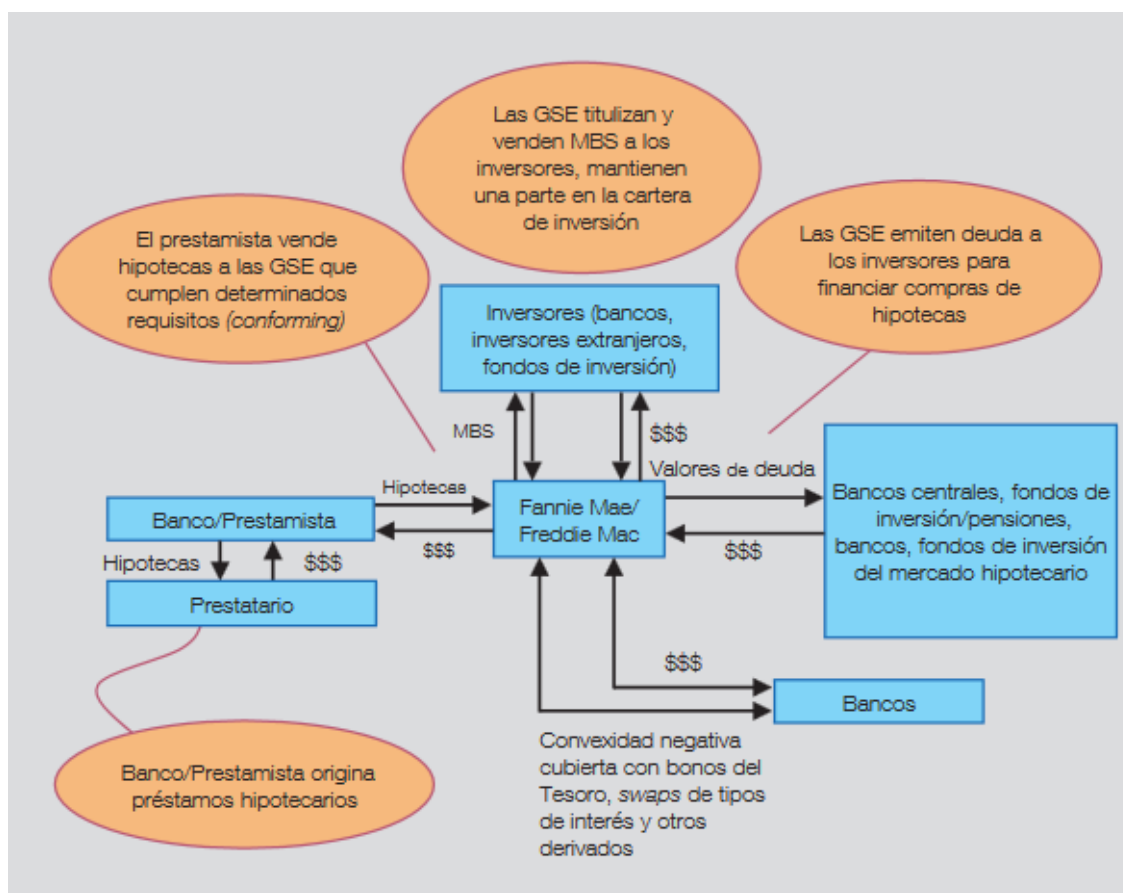


Gráfico 3.2 Funcionamiento de Fannie Mae y Freddie Mac

Fuente: FMI, tomado del Banco de España

Actualmente están en un proceso de privatización. En 2006, más del 60% de los créditos hipotecarios que adquirían eran *subprime*. Y lo peor, para pagar estas adquisiciones, recurrieron al crédito (a corto y medio plazo, cuando sus activos eran a largo, en función de las hipotecas subyacentes) y a la emisión de activos, titulizando los productos hipotecarios que adquirían, sin tener unos recursos propios suficientes para

III. LAS AGENCIAS DE CALIFICACIÓN

protegerse de situaciones adversas. Disponían de líneas de crédito del tesoro de Estados Unidos, de ventajas fiscales, de menores requerimientos de fondos propios que la banca, y su deuda era avalada por el Estado. En 2008 emitieron el 84% de los préstamos hipotecarios norteamericanos. Incluso, actualmente podrían todavía constituir un riesgo sistémico para el sistema financiero.

La evolución de los ingresos de estas compañías se muestra a continuación, en miles de millones de dólares.




Gráfico 3.3 Evolución de los ingresos de Freddie Mac y Fannie Mae

Fuente: Memorias anuales e Investopedia

y las pérdidas siguieron creciendo en los años siguientes.

La Reserva Federal no adoptó las primeras medidas de regulación de los mercados hipotecarios hasta 2008, cuando ya se habían hundido. Entre 2001 y 2006 se habían emitido activos hipotecarios con valor superior a 13 billones de dólares. Fannie Mae y Freddy Mac fueron intervenidos. Los bancos Washington Mutual y Lehman Brothers había quebrado, y otros bancos de inversión como Merrill Lynch, Goldman Sachs y Morgan Stanley quedaron en situación muy delicada; el principal grupo asegurador AIG

III. LAS AGENCIAS DE CALIFICACIÓN

tuvo que ser rescatado por el gobierno norteamericano que afrontó garantías de billones de dólares para estabilizar el sistema financiero.

El nivel de desempleo alcanzó el 10% en 2010, y se produjeron innumerables desahucios asociados al impago de hipotecas. Los precios inmobiliarios cayeron (en el estado de Nevada más del 70%) por debajo de la deuda hipotecaria.

Como los productos derivados basados en 'garantías' hipotecarias fueron vendidos en todo el mundo, las pérdidas afectaron a bancos, inversores individuales y colectivos e incluso a países, generando una crisis financiera global.

El servicio de inversores de Moody's calculaba los *ratings* de los productos estructurados en base a modelos elaborados a partir de datos en los que los mercados tuvieron un comportamiento más estable. En los momentos anteriores a la crisis, los ingresos asociados a productos derivados asociados al mercado inmobiliario suponían casi la mitad de los ingresos de la agencia, y con un crecimiento muy fuerte. En el caso de los bonos hipotecarios y sus derivados, no se había previsto una caída generalizada de los precios de la vivienda, o en los términos de la estructuración y garantías en los procesos de transmisión del riesgo, al complicarse la estructuración.

En el caso de los bancos, las carteras de bonos puntuados a partir de BBB se podían legalmente sobrevalorar en los estados contables, mientras que los de *rating* inferior se contabilizaban a su precio de adquisición (aunque su valor real fuera inferior), no siendo así para el sector asegurador. El capital regulatorio exigible a los bancos era muy bajo para activos con calificación AAA, e iba subiendo a medida que la calificación disminuía. Las regulaciones de Basilea II en Europa se basaban en unos requerimientos de capital regulatorio similares. Otras regulaciones prohibían inversiones en activos con *rating* inferior a un mínimo. Para los fondos de pensiones, este mínimo son activos de calificación A o superior. Algunos contratos privados (como el descrito de la Junta de Andalucía) condicionaban cláusulas (o activaban otras) en función de la evolución del *rating* de activos o de instituciones. Este tipo de asociación de una cláusula a algún *rating* fue uno de los factores que puso en dificultades a la principal aseguradora del

mundo, AIG. Pero lo grave es que los productos estructurados basados en garantías hipotecarias eran imposibles de valorar: si un comprador de una vivienda dejaba de pagar las anualidades de su préstamo hipotecario, y ese préstamo formaba parte de una titulización, y a su vez, esos bonos de titulización formaban parte de otro fondo (y posiblemente estos de otros, etc.), el efecto marginal de este fallido sobre el producto estructurado final era desconocido, e imposible de cuantificar. Si, debido a la caída de precios inmobiliarios muchos de estos préstamos resultaban fallidos, el efecto sobre el mercado podía ser demoledor. Y esto es lo que ocurrió.

Otra de las funciones de los *ratings* es la comparación de riesgos entre distintos activos. Así un bono de titulización con un determinado *rating* debería implicar el mismo riesgo que una obligación de la misma puntuación. Moody's disponía de tres modelos para los derivados de hipotecarios: el primero para bonos hipotecarios, otro para los productos estructurados, y el tercero, al caer el mercado, para los *subprime*. Usaban factores relacionados con la empresa, con el mercado, con la regulación, y sobre las tendencias de la economía. Es claro que las agencias no estaban preparadas para emitir *ratings* de estos productos estructurados (y sin embargo lo hicieron, y cobraron por ello; y además, los reguladores forzaban esta situación). Se emitieron calificaciones superiores a las reales que eran desconocidas para las agencias, se silenciaron objeciones internas en aras a conseguir mayor número de clientes de productos estructurados, y, los resultados se percibieron en la crisis.

En el caso de puntuar a países, los resultados son mejores (los países no encargan *ratings*).

La gente espera demasiado de los *ratings*; las inversiones de inversión deben basarse en mucho más que una puntuación, de acuerdo con uno conocido directivo de Moody's (Gary Witt), que siempre ha manifestado que sus evaluaciones son opiniones y no recomendaciones de inversión. Pero usaba información proporcionada por el emisor de los activos. Aunque la afirmación que el comité de *rating* usaba además información cualitativa, sin que se aporten datos concretos sobre ésta, que era valorada por los miembros del comité, solo cabe concluir o que esta información era irrelevante y su única función es justificar los cobros a los emisores por su evaluación, o que los miembros del comité se pueden calificar como 'expertos con claras limitaciones'. La

III. LAS AGENCIAS DE CALIFICACIÓN

rebaja de todos los tramos de los productos hipotecarios en julio de 2007 no hacía más que confirmar lo anterior.

En los escenarios considerados, se consideraba que la tendencia de los precios inmobiliarios era al alza. Durante toda la burbuja inmobiliaria, no se llegó a considerar una bajada generalizada de precios.




Gráfico 3.4 Coste (mediano) de una vivienda en EEUU (nominal y corregido de inflación)

Fuente: Census Bureau https://census.gov/construction/nrs/historical_data/index.html

De hecho, hasta entonces, los precios nominales llevaban subiendo desde los años cincuenta, con lo cual era verosímil que la tendencia fuera al alza. Sin embargo, observando los precios en dólares constantes, se observa una estabilidad con muy ligero crecimiento a largo plazo, pero, a cada período de crecimiento mayor al habitual le ha seguido una caída clara de los precios. Con el crecimiento muy pronunciado y prolongado de principios del siglo XXI cabía esperar una bajada importante; en este caso incluso de los precios nominales. Y esto originó el fallido de préstamos hipotecarios y de los productos estructurados que dependían de éstos. Observando la situación en los últimos años, es posible que en los próximos años se produzca una

caída importante, teniendo además en cuenta que estos años la inflación en los EEUU ha sido muy baja.

El utilizar a la Reserva Federal para imprimir dólares para comprar deuda y así mantener los tipos de interés próximos a cero, no solo afecta a todo el sistema financiero, sino que tiende a crear burbujas especulativas como las que se observa en el gráfico anterior.

Las agencias reconocidas como NRSRO quedaban prácticamente al margen de posterior control o regulación. Posteriormente las agencias tuvieron que hacer pública la metodología seguida (aunque, el acceso a los datos usados en sus modelos internos es lo que impedía la replicación de los *ratings*, punto éste que se aborda en este trabajo).

En Europa el proceso fue más simple. Los reguladores achacaron la crisis a las agencias de calificación. Se indicó que eran negligentes e incompetentes. Lo primero por no cerciorarse de la fiabilidad de los *ratings* ya que los emisores estaban satisfechos con éstos, y además, los pagaban (Moosa, 2017), o incluso estaban obligados a ellos por la regulación. La CNMV publicó un documento (Losada, 2009) analizando posibles enfoques de regulación. Como no cabía esperar de un estudio público, propone crear un nuevo organismo internacional constituido por reguladores y empresas para establecer la regulación de la transparencia, calidad y conflictos de interés, siendo una de las principales labores publicación de estadísticas de calidad de los *ratings* (¿no sería más fácil, eficiente, y sobre todo, barato, el que las agencias proporcionaran la información sobre sus *ratings*?, o simplemente, que transmitieran periódicamente esta información a los organismos reguladores o estadísticos); también propone crear un organismo (otros más) como el NRSRO de los EEUU, a pesar de tener comprobado que los resultados no habían sido adecuados. También se indica que una agencia podría perder su condición de tal, si se producen errores importantes (para esto tampoco haría falta ningún organismo).

III. LAS AGENCIAS DE CALIFICACIÓN

En 2004, a través de unas consultas que en definitiva propusieron una autorregulación, la Organización Internacional de Comisiones de Valores (IOSCO) publicó un documento sobre las pautas que debían seguir las agencias. Propuso la incomunicación dentro de las agencias, entre los evaluadores y la consultoría a empresas, realizadas por las agencias a los emisores, y recomendó hacer pública la metodología.

No parece que estas recomendaciones sean las que vayan a mejorar la calidad de los *ratings*. Alternativamente se podrían:

- separar en empresas distintas los servicios de asesoría de los de *rating*,
- hacer pública, tras un período prudente, toda la información y actas de reuniones en las que se decidieron las calificaciones,
- introducir un factor de responsabilidad, incluyendo la económica y la licencia de ejercicio como agencia, para caso de fallos escandalosos y en los que se pueda establecer la negligencia de la agencia,
- establecer que la metodología empleada tenga un carácter predictivo, y no en base a la información proporcionada por el emisor, y
- permitir que cualquier profesional cualificado o empresa especializada pudiera emitir *ratings*, eliminando en lo posible las barreras de entrada a la industria.

No es previsible que las agencias admitieran una regulación en estos términos, e incluso, no está tan claro que con este tipo de regulación mejorasen los informes de calificación. Aunque, la ausencia total de responsabilidad no presagia que surja una presión interna permanente para aumentar la fiabilidad de los *ratings*.

IV MÉTODOS ESTADÍSTICOS DE CLASIFICACIÓN PARA RATINGS

4.1. Introducción

4.2. Métodos estadísticos de clasificación

4.3. Métodos basados en técnicas de Inteligencia Artificial

4.1. Introducción

El problema de predicción o de reproducción de los *ratings* que generan las agencias de acreditación, es, desde el punto meramente estadístico, un problema de clasificación. El nivel de desagregación puede ser mayor o menor. En las tablas de clasificación de las puntuaciones a largo plazo, se muestran 24 niveles para S&P's y para Fitch, reduciéndose a 21 en el caso de Moody's; no obstante, dado que en las categorías inferiores no hay prácticamente empresas (pues o han desaparecido o están en fase de liquidación o absorción), se consideran las categorías inferiores, que se engloban bajo la denominación D para S&P's (incluyendo los niveles CC, C, RD, SD y D) y Ca (formado por los niveles Ca y C) para Moody's. Así, para ambas agencias se consideran 20 niveles de *rating*. Las calificaciones a corto plazo incorporan menos niveles para las tres agencias.

Por lo tanto, se trata de un problema de clasificación con un número elevado de subpoblaciones, con la dificultad adicional que, en las clases más extremas, tanto en la parte superior de la tabla, como en la inferior, la información estadística disponible es más escasa (por ejemplo, en los niveles inferiores van quedando menos empresas, debido a los fallidos).

Moody's <u>STANDARD</u> <u>& POOR'S</u> FitchRatings						Rating description
Long-term	Short-term	Long-term	Short-term	Long-term	Short-term	
Aaa	P-1	AAA	A-1+	AAA	F1+	Prime
Aa1		AA+		AA+		High grade
Aa2		AA		AA		
Aa3		AA-		AA-		
A1		P-2	A+	A-1	A+	F1
A2	A		A			
A3	A-		A-2	A-	F2	Lower medium grade
Baa1	BBB+			BBB+		
Baa2	P-3		BBB	A-3	BBB	F3
Baa3		BBB-	BBB-			
Ba1	Not Prime	BB+	B	BB+	B	Non-investment grade speculative
Ba2		BB		BB		
Ba3		BB-		BB-		
B1		B+		B+		Highly speculative
B2		B		B		
B3		B-		B-		
Caa1		CCC+	C	CCC+	C	Substantial risks
Caa2		CCC		CCC		
Caa3		CCC-		CCC-		Extremely speculative
Ca		CC		CC		
		C		C		Default imminent
C		RD	D	DDD	D	In default
/		SD		DD		
/		D		D		

Tabla 4.1 Ratings a corto y largo plazo para las tres agencias.

Fuente: Investopedia

La mayoría de los autores que han abordado este problema han recurrido a agregar clases contiguas, para así reducir la problemática de tantas puntuaciones. En el caso de *ratings* a largo, una clasificación mucho más abordable es predecir si una calificación es *prime* o *non prime*.

En nuestro caso, el problema de la clasificación será abordado con distintos niveles de agregación, llegando a plantear la predicción en la totalidad de las clases, y, como se verá, los resultados son más precisos que los que se pueden encontrar en la literatura.

La mayor parte de los trabajos sobre predicción de las puntuaciones crediticias, se centran en la obtención de los *ratings* de emisiones de activos, como bonos u obligaciones. En esta memoria se aborda la predicción para empresas, a largo plazo.

Fitch, (2018), describe la metodología que emplea, y las variables de la parte cuantitativa que emplea. Altman y Rijken (2004) analizan como puede conseguirse una cierta estabilidad en los *ratings* empresariales. Otros autores como Bissoondoyal-Bheenick y Treepongkaruna, (2011), se centran en la obtención de puntuaciones de empresas financieras, y en especial del sector bancario en Australia y en el Reino Unido, concluyendo que la calidad de los activos, el control del riesgo de liquidez, la estructura de capital y los beneficios son los determinantes de los *ratings* de las entidades. Gogas *et al* (2013), introducen un modelo de predicción de puntuaciones para estas empresas, en base a métodos numéricos. Ptak-Chmielewska, (2016), y Novotna, (2012), utilizan métodos estadísticos alternativos para realizar las clasificaciones. Fons (1991) introduce una metodología para predecir las probabilidades de fallido, y en la misma línea están los desarrollos de Keenan *et al* (1999). Altman, (2010) propone una métrica novedosa para estimar el riesgo de crédito en empresas no financieras, en base a estados contables trimestrales durante veinte años; utilizan modelos logísticos multivariantes para predecir probabilidades de fallido, para todo el espectro de *ratings* disponibles; investigan un conjunto amplio de posibles variables causales de un 'evento de crédito' para una empresa, e incorporan información macroeconómica. También Altman *et al.* (2017) vuelve sobre esta problemática incorporando una información mucho más amplia. Gangolf *et al*, (2016), proporcionan una comparación muy completa sobre distintos métodos cuantitativos utilizados en la predicción de las puntuaciones de crédito, no sólo usando procedimientos estadísticos, sino también otros basados en la Inteligencia Artificial y el análisis de grandes volúmenes de datos. Karminsky y Khromova, (2016), proponen un enfoque para la predicción de las puntuaciones en el sector bancario utilizando modelos probit

ordinales. Khemakhem y Boujelbène, (2015), elaboran un modelo para predecir los *ratings* en Túnez. Tsai y Wu (2008) usan redes neuronales para obtener probabilidades de fallido, así como Gangolf *et al* (2016). Mayer *et al*, (2017), intentan validar las puntuaciones, siguiendo los métodos usados por las agencias, pero incorporando la influencia del ciclo de los negocios. Metz, (2006), desde Moody's, describe varias aproximaciones alternativas en la estimación de las puntuaciones. Kumar y Haynes, (2003), utilizan modelos basados en redes neuronales así como en técnicas multivariantes de discriminación para obtener los *ratings* en distintos contextos. Caridad *et al* (2019) abordan el problema de predicción de *ratings* agregados usando diversas técnicas estadísticas y modelos basados en redes de tipo perceptrón.

En el campo de la predicción de puntuaciones asociadas a bonos, se han empleado varios métodos estadísticos que alcanzan un nivel de fiabilidad alta o media; los métodos basados en la Inteligencia Artificial son especialmente adecuados, sobre todo al incorporar procesos de aprendizaje automático. Otros métodos basados en modelos SVM (*Support Vector Machines* o Máquinas de Vectores de Soporte, formados por algoritmos de aprendizaje supervisado, desarrollados en los laboratorios de la empresa ATT) han sido utilizados por varios autores, como Kaplan y Urwitz (1979) o por Saha y Waheed (2017).

Estas técnicas pueden extrapolarse para obtener los *ratings* de empresas, como veremos, ventajosamente sobre los clásicos métodos de estadística multivariante. Devasena (2014), compara los resultados obtenidos usando modelos logísticos multivariantes y árboles de decisión para clasificar el riesgo de crédito. Kim y Ahn, (2012), usan las técnicas SVM así como Campos, (2012), que lo aplica para predecir las puntuaciones de crédito, pero limitándolo a siete niveles. Dima y Vasilache, (2016), usan una muestra grande de firmas para estimar los *ratings* respectivos usando redes neuronales.

En resumen, numerosas técnicas estadísticas y de modelos basados en la Inteligencia Artificial aparecen en la literatura sobre predicción de puntuaciones crediticias, aunque la mayoría se centran en obtener el *rating* de emisiones de activos financieros, y muchas

menos, en valorar a las propias empresas, y, generalmente, agregando las categorías de *ratings* en subconjuntos de niveles que limitan la aplicabilidad de las puntuaciones. Aunque, esto también está relacionado con las limitaciones de material estadístico. Las redes neuronales artificiales constituyen un instrumento cómodo y fácil de usar, tanto en problemas de modelización como de clasificación, como es el caso que nos ocupa. Las redes neuronales se representan habitualmente mediante un grafo o diagrama causal en las que aparecen variables causales o de entrada (las exógenas), y variables de salida (las endógenas o la variable de clasificación representada mediante variables artificiales binarias en función del número de subpoblaciones). Estas variables observables constituyen las denominadas capas de entrada y de salida, respectivamente, de forma similar a como se podría representar el esquema causal de un modelo econométrico uni o multiecuacional. La información se transmite a través de un sistema de variables latentes (denominadas neuronas), agrupadas en capas. A una neurona le llega información desde las variables que constituyen la capa anterior a la que pertenece, a través de caminos causales, agregándose esta información mediante una combinación lineal de los inputs. Los coeficientes de esta combinación lineal son parámetros a estimar en el modelo. En esta neurona, se produce (o no) una información de salida, a través de una función (denominada, de activación), transmitiéndose a las variables de las capas siguientes. Y así hasta llegar a la capa de salida, en la que se intenta reproducir lo mejor posible el conjunto de variables endógenas de la red. El modelo final es de tipo no lineal, y depende de varias actuaciones intermedias, como las transformaciones de la información de entrada, las funciones de activación, las transformaciones en la capa de salida, y otras. La estimación de los parámetros se realiza mediante un método iterativo, hasta conseguir que las estimaciones de las variables endógenas sean lo más precisas posibles.

En nuestro caso se han empleados redes del tipo MLP (perceptrón multicapa) usando el módulo de redes del programa SPSS (versión 26). Las variables de salida de la red son las calificaciones crediticias a largo plazo a empresas, obtenidas por S&P's y por Moody's. Las variables de entrada a la red son obtenidas de los estados contables de una muestra (de hecho, dos muestras) de empresas que han sido calificadas por S&P's, por Moody's o por ambas empresas. Estas variables o algunos ratios financieros derivadas de éstas constituyen la capa de entrada de la red, y la información se traslada a una capa

oculta de neuronas, para transmitirse finalmente a la capa de salida. El procedimiento de estimación, denominado de propagación hacia atrás, comienza asignando unos valores iniciales a los parámetros asociados a cada neurona, y obtiene la estimación de las variables de salida o endógenas, generándose unos errores o residuos. Posteriormente se van cambiando los parámetros, empezando desde la capa de salida hasta la de entrada, para mejorar la capacidad predictiva de la red. El proceso de minimización de los errores es de tipo recursivo, y se basa en un método numérico de desplazamiento calculando el gradiente máximo para acelerar el proceso de convergencia. Este procedimiento termina cuando los parámetros estimados se estabilizan en los valores finales. El proceso de estimación de los parámetros de una red, en terminología de la bibliografía de redes neuronales, se denomina 'entrenamiento' de la red. Posteriormente, con un subconjunto de casos no utilizados en la estimación de los parámetros, se procede a estimar los valores de las variables endógenas (esto es las clasificaciones reales de estas empresas por S&P's y por Moody's), para medir la capacidad predictiva de la red. Lógicamente, se dispone de varias medidas de ajuste, como en cualquier modelo, así como de otras medidas para poder juzgar la importancia relativa de las variables exógenas en las predicciones finales.

La utilización de la red exige que se tomen varias decisiones sobre otros aspectos de la misma, como las transformaciones normalizadoras de las variables para la normalización de las variables de entrada de la red, la función de activación que controla la salida de información de cada neurona, y algunos parámetros sobre el proceso numérico de estimación.

La especificación del modelo de red a emplear se realiza, en SPSS, seleccionando el número de capas ocultas, y el número de neuronas en éstas. Esta especificación, en la terminología de redes neuronales, se denomina 'topología' de la red.

En el caso que nos ocupa, los casos se han seleccionado en las bases de datos de Bloomberg, que son públicas, pero con un coste de acceso elevado.

Como el uso de redes neuronales requiere disponer de abundante información estadística, se han seleccionado más de mil empresas en cada una de las dos muestras analizadas, muestras que se describen en el capítulo siguiente. En cada empresa se han seleccionado quince variables económicas y financieras, y se disponen datos para un período que abarca desde 2004 hasta 2018, último ejercicio disponible en la actualidad. No obstante, se han seleccionado cinco años para los cálculos presentados.

Se proponen varios métodos de predicción de los *ratings*, tanto de corte transversal como dinámico, estudiando posteriormente su capacidad predictiva.

La predicción de las calificaciones crediticias otorgadas por las agencias de calificación requiere el uso de información estadística pública, ya que la información cualitativa usada por estas compañías es reservada. Para ello es preciso disponer de información fiable y abundante relacionada con la capacidad de cumplimiento de las obligaciones crediticias, y realizar un proceso de modelización adecuado. En este caso, y comparativamente con otros modelos, las redes neuronales artificiales (Alpaydin, 2018) proporcionan una herramienta flexible, que incorpora posibles no linealidades en las relaciones causales del *rating*; entre ellas, el perceptrón multicapa (MLP) aunque requiere disponer muestras grandes. Para estimar una RN predictora de las calificaciones crediticias, o, de manera similar, para evaluar la capacidad de cumplir con los compromisos financieros, es posible usar diversas variables provenientes de los estados contables. Maher y Sen (1997) y Huang *et al* (2004) sugieren emplear los recursos propios y el nivel de endeudamiento así como Horrigan (1966); Kaplan y Urwitz, (1979), el capital social; algunos autores como Kim y Ahn (2012), usan una técnica denominada 'máquinas vectoriales. O Mushang y Sin-Jin, (2014), que usan algoritmos genéticos, o Irmatova (2017), que emplea modelos no paramétricos (aunque aplicado a *ratings* de países. La mayoría tienen en cuenta el tamaño de la compañía para predecir su estabilidad para atender los compromisos crediticios, incluyendo el nivel de endeudamiento, los resultados del ejercicio, el nivel de liquidez o de inversión y las ventas, como Shin *et al*, (2005); también se han empleado magnitudes financieras como el EBITDA, el ROE, o el nivel de capitalización e incluso la valoración de CDS, y otras. En definitiva, diversos autores han ensayado el uso de variables indicativas de la

salud financiera o de algunos aspectos relacionados con esta como la situación de endeudamiento, de liquidez o incluso de volatilidad de la capitalización bursátil de la empresa utilizando distintas técnicas estadísticas y econométricas.

A partir de las variables de estados contables de una muestra aleatoria de compañías extraída de la base de datos de Bloomberg, se han obtenido una serie de ratios como elementos para la predicción de la cotización. Los ratios considerados en el modelo propuesto son los siguientes:

- $R_1 = \text{Margen del EBITDA} = \text{EBITDA} / \text{Nivel de ventas}$
- $R_2 = \text{Margen del EBIT} = \text{EBIT} / \text{Nivel de ventas}$
- $R_3 = \text{Margen de resultado neto} = \text{Intereses pagados} / \text{Nivel de ventas}$
- $R_4 = \text{Cobertura de intereses} = \text{Intereses pagados} / \text{EBITDA}$
- $R_5 = \text{Ratio de deuda sobre fondos propios} = \text{Deuda total} / (\text{Deuda total} + \text{Capital})$
- $R_6 = \text{Ratio de deuda financiera neta sobre EBITDA} = (\text{Deuda total} - \text{liquidez de activos a corto}) / \text{EBITDA}$
- $R_7 = \text{Autonomía financiera} = \text{Capital} / \text{Activo no corriente}$
- $R_8 = \text{Deuda total} / \text{Cash flow}$
- $R_9 = \text{Flujo de caja libre} = \text{Cash flow} + \text{dividendos} + \text{CAPEX}$

El objetivo es predecir las calificaciones propuestas por la principal agencia, S&P's y por Moody's, a partir de una muestra aleatoria de datos de panel de compañías tomada en la citada base de datos de Bloomberg. De hecho se dispone de dos muestras que abarcan, cada una, un período de cinco años: la primera en la que se centra la mayor parte del desarrollo, corresponde al período 2014-2018, y la segunda, otra muestra distinta que abarca el período 2010-2014.

En ambas muestras son más frecuentes las valoraciones en las categorías 'prime' entre BBB- y AA-, en las cuales se encuentran catalogadas la mayoría de las empresas. Es

bastante menos frecuente encontrar (en la población de empresas calificadas) aquellas cuya valoración es AA o superior. Entre las valoraciones 'not prime' las más frecuentes son las valoradas en el grupo de BB seguidas de las de las calificaciones B. Lógicamente, existen menos compañías en las categorías inferiores, pues las empresas situadas en éstas, o se recuperan a corto plazo o tienden a desaparecer o ser absorbidas. La distribución de la muestra se corresponde, pues, con la de la población formada por todas las empresas calificadas.

El proceso de modelización utilizando redes neuronales artificiales es práctico, por la posibilidad de disponer de modelos versátiles y fáciles de usar, siempre que se disponga de información estadística suficiente. Otras técnicas multivariantes han sido aplicadas con éxito relativo. Los modelos de Análisis Discriminante están limitados por la linealidad de las funciones discriminantes (o el uso de funciones cuadráticas), cuando las relaciones entre los ratios financieros no suelen ser lineales. Modelos logísticos o similares, multinomiales, han sido también usado con resultados variables. Las redes neuronales se emplean desde los ochenta aunque el rápido incremento de las posibilidades computacionales las convierten en un instrumento idóneo para este tipo de modelización; tienen el inconveniente de precisar un elevado número de datos.

En la predicción del *rating* de compañías, en la literatura, se observa la agregación de distintas categorías de calificaciones; lógicamente un mayor nivel de agregación conlleva una mejora en la predicción. Algunos autores como Garavaglia (1991) tratan de predecir diecisiete clases sin agregar, aunque solo alcanza un 23% de estimaciones correctas, mientras que si se agregan las categorías reduciéndolas a tres (de inversión, especulativo y el grado D), cabe alcanzar el 84% de aciertos.

En este apartado se describen los métodos empleados en este trabajo, aunque existen otros métodos de clasificación estadística que también pueden utilizarse.

4.2. Métodos estadísticos de clasificación

En el caso de predicción del *rating* de una empresa o de un activo financiero, se trata básicamente de realizar una clasificación de una variable Y ordinal a partir de una serie de variables exógenas, generalmente de tipo numéricas. En Estadística Multivariante existen varios modelos de clasificación como son los métodos de análisis discriminante, o los modelos de variable endógena no numérica, como por ejemplo, los modelos logísticos.

Los métodos de análisis discriminante suelen producir peores resultados, y cuando se prueba su poder predictivo usando métodos *jackknife* (excluyendo cada vez un caso, que es clasificado a partir de las funciones discriminantes obtenidas con el resto), la capacidad de clasificación disminuye. Se expone un resumen siguiendo a Caridad (2018).

Los modelos logit (o similares) multinomiales producen resultados parecidos a los de análisis discriminante, aunque pueden usarse con muestras más pequeñas. Si se agrupan las categorías, los resultados mejoran sustancialmente.

Análisis discriminante

Es una técnica de clasificación entre g poblaciones p -variantes $\Pi_1, \Pi_2, \dots, \Pi_g$, conocidas, de las que se dispone información estadística formada por n casos de los cuales n_1 se han obtenido en Π_1 , n_2 en Π_2 , ..., y n_g en Π_g ; con ésta se construyen unas reglas de discriminación para poder clasificar una nueva observación, \vec{x} , de la que se ignora su procedencia, en una de las g poblaciones. En el caso de predicción de *ratings*, estas variables son las correspondientes a datos económico-financieros de las empresas estudiadas.

En la población o grupo Π_j se observa la variable \vec{x} a la que se añade el subíndice j para identificar la población de origen

$$\vec{\mathbf{x}}_j = \begin{pmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{pj} \end{pmatrix} \quad j = 1, 2, \dots, g$$

De esta variable se dispone de n_j datos o casos que se agrupan en la matriz

$$\mathbf{X}_j = \begin{pmatrix} x_{1j1} & x_{2j1} & \cdots & x_{pj1} \\ x_{1j2} & x_{2j2} & \cdots & x_{pj2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1jn_j} & x_{2jn_j} & \cdots & x_{pjn_j} \end{pmatrix} = \begin{pmatrix} \vec{\mathbf{x}}'_{j1} \\ \vec{\mathbf{x}}'_{j2} \\ \vdots \\ \vec{\mathbf{x}}'_{jn_j} \end{pmatrix}$$

Por lo tanto, para proceder a un análisis discriminante, se parte de la matriz de datos observados en cada una de las poblaciones, y que se representa mediante

$$\mathbf{X} = \begin{pmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \\ \vdots \\ \mathbf{X}_g \end{pmatrix}$$

con $n = n_1 + n_2 + \dots + n_g$ filas y p columnas. Cada caso o dato constituye una fila.

Existen diversos métodos para realizar una clasificación entre varias poblaciones. Si se conoce la forma de la distribución de la variable $\vec{\mathbf{x}}$ en cada población, la discriminación máximo-verosímil clasifica un nuevo dato en aquella población para la que la función de verosimilitud, L_j , es máxima. En el caso que se conozcan probabilidades a priori, p_j , de pertenencia del nuevo dato a la población j -ésima, la regla de Bayes clasifica un nuevo caso maximizando la probabilidad a posteriori de pertenencia, $p_j L_j$. Si las g poblaciones son Normales, se distingue entre el caso de ser iguales sus respectivas matrices de covarianzas, dando origen a funciones discriminantes lineales o a aplicar la distancia de Mahalanobis, de si no lo son, resultando funciones discriminantes cuadráticas. Otra forma de abordar el problema es mediante las funciones canónicas discriminantes, optimizando un criterio estadístico de ‘máxima separación’ entre las

poblaciones; este criterio coincide con el máximo verosímil, al aplicarlo a $g = 2$ poblaciones Normales.

Las g variables que componen \vec{x}_j se suponen aleatorias, siendo sus vectores de medias y sus matrices de covarianzas respectivas

$$E[\vec{x}_j] = \vec{\mu}_j = \begin{pmatrix} \mu_{1j} \\ \mu_{2j} \\ \vdots \\ \mu_{pj} \end{pmatrix} \quad V[\vec{x}_j] = \Sigma_j = \begin{pmatrix} \sigma_{1j}^2 & \sigma_{12j} & \cdots & \sigma_{1pj} \\ \sigma_{12j} & \sigma_{2j}^2 & \cdots & \sigma_{2pj} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1pj} & \sigma_{2pj} & \cdots & \sigma_{pj}^2 \end{pmatrix}$$

para $j = 1, 2, \dots, g$.

A veces se formula una hipótesis de homocedasticidad entre las poblaciones

$$\Sigma_1 = \Sigma_2 = \dots = \Sigma_g = \Sigma$$

También es frecuente admitir una hipótesis de Normalidad

$$\vec{x}_j \in N(\vec{\mu}_j; \Sigma_j) \quad j = 1, 2, \dots, g$$

en cuyo caso cabe clasificar mediante el método basado en la función de verosimilitud, y, si se conocen probabilidades a priori de pertenencia a cada población, mediante la regla de Bayes. El admitir que la distribución de las \vec{x}_j es Normal, permite realizar contrastes de hipótesis sobre la igualdad de los vectores de medias y sobre la homocedasticidad de las poblaciones. Es claro que si alguna de las p componentes de \vec{x} no es una variable continua (por ejemplo, una variable no numérica), no será admisible la hipótesis de Normalidad.

El subíndice i se usará para designar a la variable x_i , $i = 1, 2, \dots, p$, componente i -ésima de \vec{x}_j , el subíndice j para la población Π_j , $j = 1, 2, \dots, g$, y el subíndice t , para representar el dato t -ésimo, $t = 1, 2, \dots, n_j$, de cada variable. Así, \vec{x}_{ij} será un vector que contiene las n_j observaciones de la variable x_i , medidas en la población Π_j .

En la población Π_j las medias, varianzas y covarianzas de cada variable son

$$\bar{x}_{ij\bullet} = \frac{1}{n_j} \sum_{t=1}^{n_j} x_{ijt} \quad s_{ij}^2 = \frac{1}{n_j} \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{ij\bullet})^2 \quad s_{ii^*j} = \frac{1}{n_j} \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{ij\bullet})(x_{i^*jt} - \bar{x}_{i^*j\bullet})$$

para $i, i^* = 1, 2, \dots, p$.

Estas medidas se agrupan en los vectores de medias estimadas y matrices de covarianzas de Π_j

$$\vec{\bar{\mathbf{x}}}_j = \begin{pmatrix} \bar{x}_{1j\bullet} \\ \bar{x}_{2j\bullet} \\ \vdots \\ \bar{x}_{pj\bullet} \end{pmatrix} \quad \mathbf{S}_j = \begin{pmatrix} s_{1j}^2 & s_{12j} & \cdots & s_{1pj} \\ s_{12j} & s_{2j}^2 & \cdots & s_{2pj} \\ \vdots & \vdots & \ddots & \vdots \\ s_{1pj} & s_{2pj} & \cdots & s_{pj}^2 \end{pmatrix} = \frac{1}{n_j} \dot{\mathbf{X}}_j' \dot{\mathbf{X}}_j$$

para $j = 1, 2, \dots, g$.

La matriz de datos centrados de la población Π_j es

$$\dot{\mathbf{X}}_j = \begin{pmatrix} x_{1j1} - \bar{x}_{1j\bullet} & x_{2j1} - \bar{x}_{2j\bullet} & \cdots & x_{pj1} - \bar{x}_{pj\bullet} \\ x_{1j2} - \bar{x}_{1j\bullet} & x_{2j2} - \bar{x}_{2j\bullet} & \cdots & x_{pj2} - \bar{x}_{pj\bullet} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1jn_j} - \bar{x}_{1j\bullet} & x_{2jn_j} - \bar{x}_{2j\bullet} & \cdots & x_{pjn_j} - \bar{x}_{pj\bullet} \end{pmatrix}$$

Las correspondientes matrices de cuasi covarianzas son

$$\bar{\mathbf{S}}_j = \frac{1}{n_j - 1} \dot{\mathbf{X}}_j' \dot{\mathbf{X}}_j \quad j = 1, 2, \dots, g$$

La matriz de sumas de cuadrados *intra-grupos* es

$$\mathbf{W} = \sum_{j=1}^g \dot{\mathbf{X}}_j' \dot{\mathbf{X}}_j = \sum_{j=1}^g n_j \mathbf{S}_j$$

De igual forma se definen la media y la matriz de covarianzas global:

$$\vec{\bar{\mathbf{X}}} = \begin{pmatrix} \bar{x}_{1..} \\ \bar{x}_{2..} \\ \vdots \\ \bar{x}_{p..} \end{pmatrix} \quad \mathbf{S} = \begin{pmatrix} s_1^2 & s_{12} & \cdots & s_{1p} \\ s_{12} & s_2^2 & \cdots & s_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ s_{1p} & s_{2p} & \cdots & s_p^2 \end{pmatrix} = \frac{1}{n} \dot{\mathbf{X}}' \dot{\mathbf{X}} = \frac{1}{n} \mathbf{T}$$

siendo

$$\bar{x}_{i.} = \frac{1}{n} \sum_{j=1}^g \sum_{t=1}^{n_j} x_{ijt} \quad s_i^2 = \frac{1}{n} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{i..})^2 \quad s_{ii^*} = \frac{1}{n} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{i..})(x_{i^*jt} - \bar{x}_{i^*..})$$

y $n = n_1 + n_2 + \dots + n_g$ el número total de datos en las g muestras. La matriz de sumas de cuadrados *totales* $\mathbf{T} = n\mathbf{S} = \dot{\mathbf{X}}' \dot{\mathbf{X}}$ y la matriz de sumas de cuadrados *entre grupos*

$$\mathbf{B} = \sum_{j=1}^g n_j (\vec{\bar{\mathbf{x}}}_{j.} - \vec{\bar{\mathbf{x}}}_{..})(\vec{\bar{\mathbf{x}}}_{j.} - \vec{\bar{\mathbf{x}}}_{..})'$$

La covarianza total, s_{ii^*} , se descompone en dos sumandos: la covarianza entre grupos y la covarianza intra-grupos o residual

$$\begin{aligned} s_{ii^*} &= \frac{1}{n} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{i..})(x_{i^*jt} - \bar{x}_{i^*..}) = \frac{1}{n} t_{ii^*} = \\ &= \frac{1}{n} \sum_{j=1}^g n_j (\bar{x}_{ij.} - \bar{x}_{i..})(\bar{x}_{i^*j.} - \bar{x}_{i^*..}) + \frac{1}{n} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{ij.})(x_{i^*jt} - \bar{x}_{i^*j.}) = \frac{1}{n} b_{ii^*} + \frac{1}{n} w_{ii^*} \end{aligned}$$

por lo que, el teorema de descomposición de la matriz de covarianzas total, \mathbf{S} , o de la matriz de sumas de cuadrados total, \mathbf{T} , establece que

$$\mathbf{T} = \mathbf{B} + \mathbf{W}$$

Para los datos tipificados, se usa la notación

$$\ddot{\mathbf{x}}_j = \begin{pmatrix} (x_{1j} - \bar{x}_{1j.}) / \bar{s}_{1j} \\ (x_{2j} - \bar{x}_{2j.}) / \bar{s}_{2j} \\ \vdots \\ (x_{pj} - \bar{x}_{pj.}) / \bar{s}_{pj} \end{pmatrix} \quad j = 1, 2, \dots, g$$

Existen varios procedimientos para construir reglas de clasificación. Unos se basan en la información muestral exclusivamente, y otros utilizan información previa basada en las probabilidades a priori de pertenecer a cada población, dando origen a la regla de Bayes. Si, además, se tiene información sobre las consecuencias de errar en la clasificación (a través de una función de costes de clasificación incorrecta), cabe introducir ésta en el proceso de decisión. La clasificación basada exclusivamente en la información muestral, se plantea, en primer lugar, a través de la función de verosimilitud, particularizando los resultados cuando las poblaciones son Normales (obteniendo funciones de clasificación lineales, caso de ser iguales las respectivas matrices de covarianzas, o cuadráticas, si no lo son); a continuación se introducen las funciones canónicas discriminantes de Fisher, basadas en un proceso de optimización similar al seguido en el análisis en componentes principales.

Si se conoce la forma de la distribución de la población Π_j se puede especificar su función de verosimilitud $L_j(\vec{x}) = f(\vec{x}, \theta_j)$, siendo θ_j los parámetros de dicha distribución. Dada una observación \vec{x} que se desea clasificar en una de las g poblaciones, se considerará que proviene de la población j_0 tal que

$$\max L_j(\vec{x}) = L_{j_0}(\vec{x})$$

Si además se conocen las probabilidades a priori, p_1, p_2, \dots, p_g , de pertenecer \vec{x} a cada una de las poblaciones, se obtienen las probabilidades a posteriori, y se determina la población j_0 tal que

$$\max p_j L_j(\vec{x}) = p_{j_0} L_{j_0}(\vec{x})$$

Finalmente, si se conocen los costes de clasificar erróneamente a \vec{x} , se pueden introducir estos costes en el proceso de clasificación usando la regla de Bayes.

Al particularizar estos criterios al caso de poblaciones Normales, se obtendrán unas funciones de clasificación lineales o cuadráticas.

Si las g poblaciones son Normales, $\vec{x}_j \in N(\vec{\mu}_j; \Sigma_j)$, $j = 1, 2, \dots, g$, la función de verosimilitud es

$$L_j(\vec{x}) = f(\vec{x}; \vec{\mu}_j, \Sigma_j) = \frac{1}{(2\pi)^{n/2} \sqrt{\det \Sigma_j}} e^{-\frac{1}{2}(\vec{x}-\vec{\mu}_j)' \Sigma_j^{-1} (\vec{x}-\vec{\mu}_j)}$$

En la práctica se sustituyen los parámetros $\vec{\mu}_j$ y Σ_j por sus estimaciones $\vec{\bar{x}}_j$ y \bar{S}_j en el logaritmo de la función anterior

$$\ln f(\vec{x}; \vec{\bar{x}}_j, \bar{S}_j) = -\frac{n}{2} \ln(2\pi) - \frac{1}{2}(\vec{x} - \vec{\bar{x}}_j)' \bar{S}_j^{-1} (\vec{x} - \vec{\bar{x}}_j) - \frac{1}{2} \ln \det(\bar{S}_j) = -\frac{n}{2} \ln(2\pi) - d_j$$

El maximizar la verosimilitud para $j = 1, 2, \dots, g$ equivale a minimizar las funciones de clasificación cuadráticas

$$d_j = \frac{1}{2}(\vec{x} - \vec{\bar{x}}_j)' \bar{S}_j^{-1} (\vec{x} - \vec{\bar{x}}_j) + \frac{1}{2} \ln \det \bar{S}_j \quad j = 1, 2, \dots, g$$

o, si se aplica la Regla de Bayes, de

$$d_j = \frac{1}{2}(\vec{x} - \vec{\bar{x}}_j)' \bar{S}_j^{-1} (\vec{x} - \vec{\bar{x}}_j) + \frac{1}{2} \ln \det \bar{S}_j - \ln p_j \quad j = 1, 2, \dots, g$$

Por lo tanto, el caso \vec{x} se clasifica en la población j_0 tal que

$$\min d_j = d_{j_0}$$

Si las g poblaciones Normales son homocedásticas, es decir $\Sigma_1 = \dots = \Sigma_g = \Sigma$, la matriz de covarianzas común o intragrupos combinada, se estima mediante

$$\bar{S}_{IG} = \frac{(n_1 - 1)\bar{S}_1 + \dots + (n_g - 1)\bar{S}_g}{n - g}$$

y es

$$d_j = \frac{1}{2}(\vec{x} - \vec{\bar{x}}_j)' \bar{S}_{IG}^{-1} (\vec{x} - \vec{\bar{x}}_j) + \frac{1}{2} \ln \det \bar{S}_{IG} = \frac{1}{2} \vec{x}' \bar{S}_{IG}^{-1} \vec{x} - \frac{1}{2} 2 \vec{\bar{x}}_j' \bar{S}_{IG}^{-1} \vec{x} + \frac{1}{2} \vec{\bar{x}}_j' \bar{S}_{IG}^{-1} \vec{\bar{x}}_j + \frac{1}{2} \ln \det \bar{S}_{IG}$$

Las reglas anteriores son equivalentes a clasificar \vec{x} seleccionando la población j para la que se maximizar las funciones de clasificación lineales

$$d_j^* = \vec{\bar{x}}_j' \bar{S}_{IG}^{-1} \vec{x} - \frac{1}{2} \vec{\bar{x}}_j' \bar{S}_{IG}^{-1} \vec{\bar{x}}_j \quad j = 1, 2, \dots, g$$

o, equivalentemente, minimizar la distancia de Mahalanobis

$$D_j^2 = (\vec{x} - \vec{\bar{x}}_j)' \bar{\mathbf{S}}_{IG}^{-1} (\vec{x} - \vec{\bar{x}}_j)$$

de \vec{x} al grupo j -ésimo.

Si existe información a priori, se maximiza

$$d_j^* = \vec{\bar{x}}_j' \bar{\mathbf{S}}_{IG}^{-1} \vec{x} - \frac{1}{2} \vec{\bar{x}}_j' \bar{\mathbf{S}}_{IG}^{-1} \vec{\bar{x}}_j + \ln p_j \quad j = 1, 2, \dots, g$$

Por lo tanto, el caso \vec{x} se clasifica en la población j_0 tal que

$$\max d_j^* = d_{j_0}^*$$

o, usando la distancia de Mahalanobis, que

$$\min D_j^2 = D_{j_0}^2$$

La probabilidad a posteriori que \vec{x} pertenezca a la población Π_j se obtiene mediante la aplicación del teorema de Bayes

$$P(\Pi_j | \vec{x}) = \frac{e^{-d_j/2}}{\sum_{j^*=1}^g e^{-d_{j^*}/2}} \quad j = 1, 2, \dots, g$$

Estas probabilidades miden un grado de creencia o de incertidumbre, pues, en realidad \vec{x} pertenece a una de las poblaciones, es decir, no existe aleatoriedad.

La homocedasticidad de las poblaciones se contrasta con el test de Box, para utilizar funciones discriminantes lineales o cuadráticas, aunque en la práctica, es recomendable comprobar si las funciones lineales producen resultados aceptables.

Variables originales

$$z = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = \vec{\beta}' \vec{x}$$

que definen direcciones (ortogonales) en el espacio de las variables, siendo estas direcciones las que ‘separan’ más los g grupos. Permiten, a veces, visualizar las distancias entre las poblaciones.

Para obtener la primera función discriminante $z = \vec{\beta}_1' \vec{x} = \vec{\beta}' \vec{x}$, es decir, la dirección del espacio que separa más los g grupos, se plantea el modelo de análisis de la varianza siguiente, en el que las variables z no son conocidas a priori

$$z_{jt} = \beta_1 x_{1jt} + \beta_2 x_{2jt} + \dots + \beta_p x_{pjt} = \mu + \Pi_j + \varepsilon_{t(j)} \quad j = 1, 2, \dots, g \quad t = 1, 2, \dots, n_j$$

La suma de cuadrados total es

$$\begin{aligned} S_z = S_{CT} &= \sum_{j=1}^g \sum_{t=1}^{n_j} (z_{jt} - \bar{z}_{..})^2 = \sum_{j=1}^g \sum_{t=1}^{n_j} [\beta_1 x_{1jt} + \beta_2 x_{2jt} + \dots + \beta_p x_{pjt} - (\beta_1 \bar{x}_{1..} + \beta_2 \bar{x}_{2..} + \dots + \beta_p \bar{x}_{p..})]^2 = \\ &= \sum_{j=1}^g \sum_{t=1}^{n_j} [\beta_1 (x_{1jt} - \bar{x}_{1..}) + \beta_2 (x_{2jt} - \bar{x}_{2..}) + \dots + \beta_p (x_{pjt} - \bar{x}_{p..})]^2 = \\ &= \sum_{i=1}^p \sum_{i^*=1}^p \beta_i \beta_{i^*} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{i..})(x_{i^*jt} - \bar{x}_{i^*..}) = \sum_{i=1}^p \sum_{i^*=1}^p \beta_i \beta_{i^*} n s_{ii^*}^2 = \vec{\beta}' n \vec{S} \vec{\beta} = \vec{\beta}' \dot{\mathbf{X}}' \dot{\mathbf{X}} \vec{\beta} = \vec{\beta}' \mathbf{T} \vec{\beta} \end{aligned}$$

La suma de cuadrados entre grupos (*between*) es

$$\begin{aligned} S_{\Pi} = S_{CB} &= \sum_{j=1}^g \sum_{t=1}^{n_j} (\bar{z}_{j\bullet} - \bar{z}_{..})^2 = \sum_{j=1}^g n_j (\beta_1 \bar{x}_{1j\bullet} + \beta_2 \bar{x}_{2j\bullet} + \dots + \beta_p \bar{x}_{pj\bullet} - (\beta_1 \bar{x}_{1..} + \beta_2 \bar{x}_{2..} + \dots + \beta_p \bar{x}_{p..}))^2 = \\ &= \sum_{j=1}^g n_j (\beta_1 (\bar{x}_{1j\bullet} - \bar{x}_{1..}) + \beta_2 (\bar{x}_{2j\bullet} - \bar{x}_{2..}) + \dots + \beta_p (\bar{x}_{pj\bullet} - \bar{x}_{p..}))^2 = \\ &= \sum_{i=1}^p \sum_{i^*=1}^p \beta_i \beta_{i^*} \sum_{j=1}^g n_j (\bar{x}_{ij\bullet} - \bar{x}_{i..})(\bar{x}_{i^*j\bullet} - \bar{x}_{i^*..}) = \vec{\beta}' \mathbf{B} \vec{\beta} \end{aligned}$$

La suma de cuadrados intra grupos o residual (*within*) es

$$\begin{aligned} S_{\varepsilon} = S_{CW} &= \sum_{j=1}^g \sum_{t=1}^{n_j} (z_{jt} - \bar{z}_{j\bullet})^2 = \sum_{j=1}^g \sum_{t=1}^{n_j} (\beta_1 x_{1jt} + \beta_2 x_{2jt} + \dots + \beta_p x_{pjt} - (\beta_1 \bar{x}_{1j\bullet} + \beta_2 \bar{x}_{2j\bullet} + \dots + \beta_p \bar{x}_{pj\bullet}))^2 = \\ &= \sum_{j=1}^g \sum_{t=1}^{n_j} (\beta_1 (x_{1jt} - \bar{x}_{1j\bullet}) + \beta_2 (x_{2jt} - \bar{x}_{2j\bullet}) + \dots + \beta_p (x_{pjt} - \bar{x}_{pj\bullet}))^2 = \end{aligned}$$

$$= \sum_{i=1}^p \sum_{i^*=1}^p \beta_i \beta_{i^*} \sum_{j=1}^g \sum_{t=1}^{n_j} (x_{ijt} - \bar{x}_{ij\bullet})(x_{i^*jt} - \bar{x}_{i^*j\bullet}) = \sum_{i=1}^p \sum_{i^*=1}^p \beta_i \beta_{i^*} \sum_{j=1}^g n_j \mathbf{S}_j = \vec{\beta}' \sum_{j=1}^g \dot{\mathbf{X}}_j' \dot{\mathbf{X}}_j \vec{\beta} = \vec{\beta}' \mathbf{W} \vec{\beta}$$

El teorema de descomposición de la varianza de z , $S_{CT} = S_{CB} + S_{CW}$ se expresa, en notación matricial como

$$\mathbf{T} = \mathbf{B} + \mathbf{W}$$

Si la suma de cuadrados asociada a los grupos, S_{CB} , es ‘grande’ respecto a la residual, es debido a que la función z se puede emplear para discriminar entre los grupos. Por lo tanto, los coeficientes $\vec{\beta}$ de la primera función discriminante $z = \vec{\beta}_1' \vec{\mathbf{x}}$ se obtienen maximizando (con respecto a $\vec{\beta}$) el estadístico proporcional al del análisis de la varianza

$$F = \frac{S_{CB}}{S_{CW}} = \frac{\vec{\beta}' \mathbf{B} \vec{\beta}}{\vec{\beta}' \mathbf{W} \vec{\beta}}$$

Para obtener el máximo se resuelve la ecuación

$$\frac{dF}{d\vec{\beta}} = \vec{\mathbf{0}}_p = 2 \frac{(\mathbf{B}\vec{\beta} - F\mathbf{W}\vec{\beta})\vec{\beta}'\mathbf{W}\vec{\beta}}{\vec{\beta}'\mathbf{W}\vec{\beta}\vec{\beta}'\mathbf{W}\vec{\beta}} = 2 \frac{\mathbf{B}\vec{\beta} - F\mathbf{W}\vec{\beta}}{\vec{\beta}'\mathbf{W}\vec{\beta}}$$

y, por tanto,

$$\mathbf{W}^{-1}\mathbf{B}\vec{\beta} = F\vec{\beta}$$

resultando ser $\vec{\beta} = \vec{\beta}_1$ un autovector correspondiente al mayor autovalor $F = \lambda_1$ de la matriz $\mathbf{W}^{-1}\mathbf{B}$. Nótese que esta matriz no tiene por qué ser simétrica, aunque \mathbf{W} y \mathbf{B} lo sean; por lo tanto, aunque sus autovalores sean reales, los autovectores no serán en general ortogonales, y las variables canónicas no serán incorreladas.

Es necesario que no exista multicolinealidad exacta entre los n datos de las variables $\vec{\mathbf{x}}$, con objeto que sea \mathbf{W} regular.

La dirección $\vec{\beta} = \vec{\beta}_1$ de la primera función discriminante canónica, $z = \vec{\beta}_1' \vec{x}$, es la que determina la mayor separación entre los vectores de medias $\vec{\bar{x}}_j$, $j = 1, 2, \dots, g$ de las g poblaciones, cuyas proyecciones en el eje z determinan los puntos $z_j = \vec{\beta}_1' \vec{\bar{x}}_j$, $j = 1, 2, \dots, g$. La **regla de clasificación** basada en la primera función discriminante, para clasificar un nuevo caso \vec{x} se basa en proyectar esta observación sobre dicho eje, calculando $z = \vec{\beta}_1' \vec{x}$, y hallando

$$\min d_j = \min \left\{ |\vec{\beta}_1' \vec{x} - \vec{\beta}_1' \vec{\bar{x}}_j|, j = 1, 2, \dots, g \right\} = d_{j_0}$$

clasificándose \vec{x} en la población j_0 .

En el caso de $g = 2$ poblaciones, es

$$\vec{\beta} = \vec{\beta}_1 = \bar{S}_{IG}^{-1}(\vec{\bar{x}}_1 - \vec{\bar{x}}_2)$$

y es equivalente a la función lineal de clasificación de Fisher ya comentada.

La primera función canónica discriminante estandarizada es la que se obtiene realizando un análisis discriminante sobre los datos tipificados

$$\ddot{\vec{x}}_j = \begin{pmatrix} (x_{1j} - \bar{x}_{1j\bullet}) / \bar{s}_{1j} \\ (x_{2j} - \bar{x}_{2j\bullet}) / \bar{s}_{2j} \\ \vdots \\ (x_{pj} - \bar{x}_{pj\bullet}) / \bar{s}_{pj} \end{pmatrix} \quad j = 1, 2, \dots, g$$

es decir

$$z_{1j}^* = \vec{\beta}_1^* \ddot{\vec{x}}_j = \sum_{i=1}^p \beta_{i1}^* \frac{x_{ij} - \bar{x}_{ij\bullet}}{\bar{s}_{ij}} \quad j = 1, 2, \dots, g$$

Los coeficientes de la función canónica discriminante estandarizada informan sobre la importancia relativa de cada variable x_1, x_2, \dots, x_p , en el proceso de discriminación, y están relacionados con los coeficientes de la función discriminante pues

$$\beta_{i1}^* = \bar{s}_{IGi} \beta_{i1} \quad i = 1, 2, \dots, p$$

para lo cual se necesitan los elementos de la matriz de covarianzas común (intragrupos combinada) $\bar{\mathbf{S}}_{IG}$.

Una forma alternativa de obtener la primera función discriminante es maximizando el cociente

$$\frac{S_{CB}}{S_{CT}} = \frac{\vec{\beta}' \mathbf{B} \vec{\beta}}{\vec{\beta}' (\mathbf{B} + \mathbf{W}) \vec{\beta}} = \frac{\vec{\beta}' \mathbf{B} \vec{\beta}}{\vec{\beta}' \mathbf{T} \vec{\beta}} = R_c^2$$

en cuyo caso los coeficientes de la función discriminante son el autovector correspondiente al mayor autovalor de $\mathbf{T}^{-1} \mathbf{B}$. Este cociente es el coeficiente de determinación canónico, y mide la proporción de la varianza de las puntuaciones canónicas debida a las diferencias entre los g grupos, o bien, la parte de variabilidad entre grupos explicada por la primera función discriminante canónica.

Es claro que si las medias de los g grupos, $\vec{\mathbf{x}}_j$, $j = 1, 2, \dots, g$, no están alineadas (aproximadamente) en el espacio, la primera función discriminante canónica no es suficiente. Si dichas medias estuvieran (aproximadamente) contenidas en un plano, se puede definir una segunda función canónica $z = \vec{\beta}_2' \vec{\mathbf{x}}$, aplicando el mismo criterio de máxima separación entre las medias de los grupos. El vector de coeficientes $\vec{\beta}_2$ es un autovector correspondiente al segundo mayor autovalor de $\mathbf{W}^{-1} \mathbf{B}$.

La regla de clasificación, usando las dos primeras funciones canónicas se basa en asignar una nueva observación $\vec{\mathbf{x}}$ minimizando la distancia existente entre proyección de este caso a la proyección de las g medias sobre el plano canónico:

$$\min d_j^2 = \min \left\{ (\vec{\beta}_1' \vec{\mathbf{x}} - \vec{\beta}_1' \vec{\mathbf{x}}_j)^2 + (\vec{\beta}_2' \vec{\mathbf{x}} - \vec{\beta}_2' \vec{\mathbf{x}}_j)^2, \quad j = 1, 2, \dots, g \right\} = d_{j_0}^2$$

Proyectando las g medias sobre el plano canónico, se delimitan las regiones más próximas a cada una de éstas, originando el mapa territorial. Al proyectar cualquier nuevo caso sobre éste, se determina gráficamente a que población se asignaría.

Si las medias anteriores no se encuentran aproximadamente en un plano, se pueden obtener más funciones canónicas discriminantes obteniendo más autovectores de $\mathbf{W}^{-1}\mathbf{B}$.

Una forma de decidir sobre la dimensión del espacio canónico es mediante un gráfico de los autovalores de $\mathbf{W}^{-1}\mathbf{B}$. En el caso de poblaciones Normales cabe realizar contrastes sobre el número de funciones canónicas necesarias.

La matriz de estructura contiene las correlaciones entre las variables originales x_1, x_2, \dots, x_p y las funciones discriminantes z_1, z_2, \dots, z_m . Estas correlaciones se obtienen a partir de los coeficientes de correlación intragrupos y de las funciones discriminantes estandarizadas: por ejemplo, para la primera función discriminante z_1 es

$$r_{x_i z_1} = \sum_{j=1}^p r_{IGx_i x_j} \beta_j^* \quad i = 1, 2, \dots, p.$$

Se usan para analizar las variables asociadas a la función canónica discriminante.

Generalmente no todas las variables son necesarias para construir una regla de clasificación, y unas tienen más poder discriminante que otras. Se pueden seleccionar las variables más importantes usando distintos procedimientos. En todo caso, al existir multicolinealidad entre las variables discriminantes, la inclusión de una nueva variable afectará a los coeficientes de las funciones discriminantes previamente calculados. El nivel de tolerancia de una variable x_i , es $1 - R_i^2$, siendo R_i^2 el coeficiente de determinación de la regresión de esta variable con las previamente incluidas; si la tolerancia es menor que un mínimo, se considera que x_i es redundante y no se debe incluir como variable discriminante, ya que afectaría a la precisión de la estimación de los coeficientes de las nuevas funciones canónicas. Los procedimientos de selección de variables son los siguientes:

El método prospectivo consiste en ir seleccionando sucesivamente las variables con mayor poder de discriminación. La primera variable se elige realizando unos análisis de la varianza simple de la forma $x_{ijt} = \mu + \Pi_j + \varepsilon_{t(ij)}$, para cada variable, seleccionándose

aquella cuyo estadístico F del factor población, Π_j , sea mayor, y superior al nivel de significación α deseado; la segunda variable se selecciona de igual forma, pero con un modelo de análisis de covarianza, introduciendo como covariable la variable seleccionada en primer lugar. En los siguientes pasos se incluyen como covariables todas las variables seleccionadas previamente. Así se continúa hasta que no se encuentren más variables significativas a incluir. No suele ser un método recomendable, pues puede dejar fuera de las funciones discriminantes a variables relevantes.

El método retrospectivo parte del conjunto de las p variables originales y se van eliminando aquellas variables con menor poder discriminante. Inicialmente se realiza un análisis de covarianza para cada variable x_i , incluyendo como covariables todas las demás, y seleccionando la variable x_i que de lugar a un estadístico F más bajo para el factor Π_j , siempre que no sea significativo al nivel α deseado. Es el método recomendable en la práctica usando un nivel de significación bajo, como $\alpha = 0.01$.

El método paso a paso combina los anteriores. Se seleccionan las variables a incluir como en el método prospectivo, aunque antes de incluir una nueva variable, se comprueba si no hay que excluir alguna de las previamente incluidas, usando el método retrospectivo. Puede usarse si el número de variables es elevado: $p \geq 20$. El nivel de significación para incluir variables no debe ser bajo, $\alpha \geq 0.25$, y para excluir se puede tomar $\alpha = 0.15$.

En todos los casos conviene revisar los resultados de la clasificación obtenida.

También se pueden usar criterios estadísticos como incluir la variable con menor Λ de Wilks, o la que produce una mayor variación de la distancia de Mahalanobis.

IV. MÉTODOS ESTADÍSTICOS DE CLASIFICACIÓN PARA RATINGS

La importancia relativa de las variables discriminantes se mide con los coeficientes de la función discriminante estandarizada.

$$\beta_{i1}^* = \bar{s}_{IGi} \beta_{i1} \quad i = 1, 2, \dots, p$$

Los resultados de un análisis discriminante se evalúan construyendo una tabla de clasificación con los datos utilizados para construir las funciones discriminantes, o con las probabilidades a posteriori de pertenencia a cada una de las g poblaciones. Generalmente habrá casos correctamente clasificados, y otros incorrectamente. Las proporciones de casos correcta e incorrectamente clasificados en cada grupo constituyen una medida de la bondad del análisis.

El número de elementos bien clasificados figuran en la diagonal principal de la tabla.

	Clasificado en la población				
Población real	1	2	...	g	Tamaños muestrales
Π_1	n_{11}	n_{12}	...	n_{1g}	n_1
Π_2	n_{21}	n_{22}	...	n_{2g}	n_2
....
Π_g	n_{g1}	n_{g2}		n_{gg}	n_g

Para evitar los sesgos derivados de usar las funciones estimadas con unos datos para clasificar estos mismos datos, se usan para cada caso unas funciones discriminantes estimadas con $n - 1$ datos, y se clasifica el n -ésimo. Esto se repite para cada dato.

Modelos logísticos

Los modelos de regresión logística y similares son modelos de regresión no lineales, y tratan de explicar la variabilidad de una variable, y , no numérica a partir de variables explicativas exógenas (numéricas y no numéricas). Por ejemplo, y puede representar la ocurrencia o no de un siniestro, la elección de un producto entre varios por un consumidor, la aceptación o denegación de un préstamo, etc. La variable dependiente o endógena, y , puede representar dos alternativas, en cuyo caso se usa una variable binaria, que toma los valores 0 y 1; en el caso que pueda tomar g valores, uno de ellos se toma como referencia, y se usan $g - 1$ modelos binarios, con cada una de las alternativas, respecto a la referencia.

En la terminología anglosajona se usa la palabra *odds* para representar la probabilidad que ocurra un suceso A (por ejemplo, que sea $Y = 1$) respecto a la que ocurra otro suceso B (como $Y = 0$) incompatible con A. Este cociente se denomina ventaja de A sobre B. Si B es el suceso contrario de A

$$vent(A | B) = \frac{P(A)}{P(B)} = \frac{P(A)}{1 - P(A)}$$

Los modelos de regresión con variable dependiente no numérica están relacionados con el análisis discriminante, pues los g valores o categorías de la variable y pueden representar las g poblaciones, y el modelo constituirá una función de clasificación.

En el caso de ser binaria la variable endógena una especificación simple de estos modelos es

$$Y = F(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) + \varepsilon = \hat{y} + \varepsilon$$

en los que F es una función que toma valores en el intervalo $[0; 1]$. Para estimar el modelo se dispone de un conjunto de n datos $(y_i, x_{1i}, x_{2i}, \dots, x_{ki})$, para $i = 1, 2, \dots, n$, siendo las perturbaciones, variables aleatorias (binarias) tales que $E[\varepsilon_i] = 0$, y $V[\varepsilon_i] = \hat{y}_i(1 - \hat{y}_i)$, para $i = 1, 2, \dots, n$.

Como $E[\varepsilon] = 0$, es

$$E[Y] = F(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)$$

y como la media de una variable binaria es $E[Y] = p = P[Y = 1]$, resulta que

$$\hat{y} = F(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) = P[Y = 1]$$

es decir, el valor estimado, \hat{y} , representa la probabilidad que la variable Y tome el valor 1, y por lo tanto, la forma funcional $F(u)$ debe ser tal que solo pueda tomar valores en el intervalo $[0, 1]$, pues representa una probabilidad.

En los modelos logit y en los modelos probit (o normit), es, respectivamente

$$y = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}} + \varepsilon \quad y = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k} e^{-t^2/2} dt + \varepsilon.$$

Una alternativa a estas funciones es usar los modelos ‘linealizados’; para los modelos logit,

$$\text{vent}(y=1 | y=0) = \ln \frac{\hat{y}}{1-\hat{y}} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

y en el caso del modelo probit

$$\Phi(\hat{y}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$$

en la que Φ es la función de distribución de una variable $N(0; 1)$. No es equivalente estimar directamente los modelos logit o probit, o sus ‘equivalentes’ linealizados.

Para estudiar los efectos marginales de las variables exógenas sobre la endógena, Y , hay que calcular las derivadas parciales de y con respecto a cada variable explicativa. Sea $u = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$, por lo que $y = F(u) + \varepsilon$

$$\frac{\partial y}{\partial x_j} = \frac{dF}{du} \frac{\partial u}{\partial x_j} = f(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) \beta_j$$

es decir, el efecto marginal de x_j sobre Y es proporcional al coeficiente β_j de la variable x_j y del mismo signo, pues $f(u) \geq 0, \forall u$.

Es posible comparar los valores relativos de los efectos marginales de dos variables, x_j y x_m , pues

$$\frac{\frac{\partial y}{\partial x_j}}{\frac{\partial y}{\partial x_m}} = \frac{\beta_j}{\beta_m}$$

El método de máxima verosimilitud se basa en maximizar la función de verosimilitud,

$$L(\vec{\beta}) = L(\beta_0, \beta_1, \beta_2, \dots, \beta_k) = f(y_1, y_2, \dots, y_n)$$

o, de forma equivalente, su logaritmo $l(\vec{\beta}) = \ln L(\vec{\beta})$, es decir

$$\ln L(\beta_0, \beta_1, \beta_2, \dots, \beta_k) = \sum_{i=1}^n y_i \ln F(\beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki}) + (1 - y_i) \ln(1 - F(\beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki}))$$

La maximización de esta función requiere resolver un sistema de ecuaciones normales no lineales, lo que se consigue con métodos numéricos.

En el caso de modelos logit con variable endógena binaria, la función de verosimilitud es

$$L(\vec{\beta}) = \prod_{i=1}^n \left(\frac{1}{1 + e^{-(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki})}} \right)^{y_i} \left(1 - \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki})}} \right)^{1-y_i}$$

La función logarítmica de verosimilitud, $l(\vec{b}) = \ln L(b_0, b_1, \dots, b_k)$ y su media (dividiéndola por el número de datos) son dos medidas usuales, que tienden a tomar valores mayores al ser el ajuste mejor.

La función logarítmica de verosimilitud restringida $l(\vec{b}_0)$ se obtiene maximizando la función $\ln L(\beta_0, 0, \dots, 0)$, es decir, corresponde a estimar la probabilidad de ser $Y = 1$, sobre todo el conjunto de datos, sin tener en cuenta las variables exógenas. Al ser una maximización con restricciones, es $l(\vec{b}_0) \leq l(\vec{b})$, y la diferencia informa sobre la capacidad predictiva global del modelo. Así para realizar el contraste de significación global

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0$$

$$H_1: \text{algunos } \beta_j \neq 0$$

se emplea el estadístico

$$G^2 = -2[l(\vec{\mathbf{b}}_0) - l(\vec{\mathbf{b}})]$$

cuya distribución asintótica, si H_0 es cierta, es $\chi^2(k)$, y la probabilidad límite correspondiente es

$$p = P[\chi^2 > G^2]$$

Una medida de ajuste adicional es el coeficiente de McFadden, que recuerda al coeficiente de determinación, pues toma valores en el intervalo $[0, 1]$, correspondiendo los valores grandes a un mejor grado de ajuste

$$R_{MF}^2 = 1 - \frac{l(\vec{\mathbf{b}}_0)}{l(\vec{\mathbf{b}})}$$

Mide cuanto mejora el ajuste, respecto a un modelo trivial, sin variables explicativas.

Otras medidas de ajuste, son los criterios de información de Akaike, Schwarz y Hannan-Quinn

$$AIC = -\frac{2}{n}l(\vec{\mathbf{b}}) + \frac{2k}{n} \quad BIC = -\frac{2}{n}l(\vec{\mathbf{b}}) + \frac{k \ln(n)}{n} \quad HQ = -\frac{2}{n}l(\vec{\mathbf{b}}) + \frac{2k \ln \ln(n)}{n}$$

todos ellos basados en la función logarítmica de verosimilitud con un término de penalización en función del número k de variables explicativas. Al comparar dos modelos, valores mas pequeños de estos estadísticos denotan mejor ajuste.

Otros contrastes sobre los coeficientes son de la forma

$$H_0: \beta_j = 0$$

$$H_1: \beta_j \neq 0$$

para los cuales se usan los estadísticos

$$Z = \frac{b_j}{s_{b_b}}$$

cuya distribución muestral asintótica, si H_0 es cierta, tiende a una $N(0, 1)$.

Los n casos originales se clasifican de forma natural en dos grupos: aquellos para los que es $Y = 0$, y el resto, para los que es $Y = 1$. Los modelos de variable endógena binaria pueden usarse para clasificar los casos en estos dos grupos, en función de los valores \hat{y} obtenidos con el modelo.

Al estimar los valores que la probabilidad que la variable endógena tome el valor 1, esto es, $\hat{y} = P[Y = 1 | x_1, x_2, \dots, x_k]$, es posible clasificar los n datos originales (o bien, unos nuevos casos) para predecir el grupo, 0 o 1, al que pertenece cada caso. Si se determina un nivel de probabilidad, c , a partir del cual se clasifica un dato como del grupo 1, y, por debajo del mismo, se considera que es del grupo 0, se tiene el criterio

Si $\hat{y} > c \Rightarrow$ se clasifica el caso en el grupo $Y = 1$

Si $\hat{y} \leq c \Rightarrow$ se clasifica el caso en el grupo $Y = 0$

Como para los n casos originales se conoce el grupo al que pertenecen, es posible generar la tabla de clasificación siguiente

	Clase verdadera		
Clase asignada	$Y = 1$	$Y = 0$	Total
$\hat{y} > c$	b_1	e_0	\check{n}_1
$\hat{y} \leq c$	e_1	b_0	\check{n}_0
Total	n_1	n_0	n

Los errores de clasificación están constituidos por los e_0 casos que han sido clasificados en el grupo 1, cuando en realidad pertenecen al grupo $Y = 0$, y por los e_1 casos clasificados en el grupo 0, cuando realmente están en el grupo $Y = 1$. También se suelen calcular las proporciones de clasificados correctamente e incorrectamente en cada uno de los dos grupos, así como las clasificaciones que se obtendrían sin tener en cuenta ninguna de las variables explicativas (excluyéndolas de la estimación del modelo), para comprobar la capacidad predictiva del modelo. En esta tabla cabe calcular alguna medida de asociación en tablas de contingencia como la D de Sommer, las τ de Kendall, y otras.

Los modelos logísticos multinomiales son una generalización de los modelos logit con variable endógena binaria,

$$y = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}} + \varepsilon = \frac{e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}}{1 + e^{\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}} + \varepsilon = F(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k) + \varepsilon$$

siendo $\hat{y} = F(\vec{\beta}'\vec{x}) = P[Y=1|\vec{x}]$ la función de distribución logística. La segunda formulación, en la expresión anterior va a utilizarse para especificar los modelos logit multinomiales.

En estos modelos la variable y toma $p + 1$ valores, que se codifican mediante $0, 1, 2, \dots, p$, y se considerará que el valor 0 es el de referencia. Estos valores pueden constituir el espacio muestral de una variable ordenada, dando origen a los modelos logit ordenados, o, simplemente representan alternativas no ordenadas. Además, las variables explicativas pueden ser comunes para todas las categorías, o específicas (distintas) para cada valor de y . Las $p + 1$ categorías de y deben ser mutuamente excluyentes: ocurrirá una y solo una para cada caso; si no son mutuamente excluyentes, existen otros modelos multiecuacionales para tratar estos casos.

Los $p + 1$ valores de la variable y se pueden considerar como el resultado de una elección o clasificación de una variable latente (no observable) de utilidad, U , que se supone formada por una parte determinista, V , y una aleatoria, ε . Así, para el caso t -ésimo, la utilidad proporcionada por la alternativa j es $U_{jt} = V_{jt} + \varepsilon_{jt} = \tilde{\beta}_j' \tilde{\mathbf{x}}_t + \varepsilon_{jt}$. Si el caso t -ésimo (persona, empresa,...) puede elegir una alternativa, seleccionará el valor de j que maximice esta utilidad. Las variables explicativas asociadas al caso t -ésimo, $\tilde{\mathbf{x}} = \tilde{\mathbf{x}}_t$, se pueden dividir en dos partes: aquellas específicas de la alternativa j , $\tilde{\mathbf{x}}_t^{(j)}$, y otras asociadas al caso t -ésimo pero que no dependen de la alternativa j , $\tilde{\mathbf{x}}_t^*$, es decir

$$\tilde{\mathbf{x}}_t = \begin{pmatrix} \tilde{\mathbf{x}}_t^{(j)} \\ \tilde{\mathbf{x}}_t^* \end{pmatrix}$$

Los coeficientes correspondientes al modelo de predicción de la alternativa j pueden depender de ésta, y por eso se les incluye el subíndice j .

En el modelo multinomial condicional, las variables explicativas no están asociadas a los n casos, sino a las $p + 1$ alternativas de y . Los coeficientes $\tilde{\beta}$ son constantes entre las alternativas (y no se incluye un subíndice j)

Sobre la parte aleatoria de estas utilidades se pueden formular distintas hipótesis a priori, lo que lleva a formular distintos modelos multinomiales. Si las perturbaciones $(\varepsilon_{0t}, \varepsilon_{1t}, \dots, \varepsilon_{pt})$ se suponen Normales centradas y con matriz de covarianzas idéntica para los $t = 1, 2, \dots, n$ casos, el modelo resultante es el Probit multinomial, y si es de Gumbel de tipo I, el Logit multinomial.

Para predecir las probabilidades asociadas a cada uno de estos valores, hay que construir p modelos, similares a los modelos logit antes tratados. Estos modelos son

$$\hat{y}_j = F(\tilde{\beta}_j' \tilde{\mathbf{x}}) = P(Y = j | \tilde{\mathbf{x}}) = \frac{e^{\tilde{\beta}_j' \tilde{\mathbf{x}}}}{1 + \sum_{i=1}^p e^{\tilde{\beta}_i' \tilde{\mathbf{x}}}} \quad j = 1, 2, \dots, p$$

La estimación de la probabilidad que Y tome el valor 0, es decir, el tomado como referencia, se obtiene por diferencia, y es

$$\hat{y}_0 = P(Y = 0 | \vec{x}) = \frac{1}{1 + \sum_{i=1}^p e^{\vec{\beta}_i \vec{x}}}$$

La estimación de estos modelos se realiza conjuntamente, mediante el método de máxima verosimilitud, o, de forma equivalente, su logaritmo

$$l(\vec{\beta}_1, \vec{\beta}_2, \dots, \vec{\beta}_p) = \ln L(\vec{\beta}_1, \vec{\beta}_2, \dots, \vec{\beta}_p)$$

siendo

$$L(\vec{\beta}_1, \vec{\beta}_2, \dots, \vec{\beta}_p) = \prod_{t=1}^n \hat{y}_0(\vec{x}_t)^{y_{0t}} \hat{y}_1(\vec{x}_t)^{y_{1t}} \dots \hat{y}_p(\vec{x}_t)^{y_{pt}} \quad \hat{y}_0 + \hat{y}_1 + \dots + \hat{y}_p = 1$$

Los exponentes son las variables artificiales $y_j = 1$ si $Y = j$, e $y_j = 0$ en los demás casos.

La maximización de esta función requiere resolver el sistema no lineal resultante de igualar sus primeras derivadas parciales a cero. Para estimar las desviaciones típicas (asintóticas) de los coeficientes de regresión, se usa la inversa de la matriz de información, \mathbf{I} , de la función logarítmica de verosimilitud, es decir, la inversa de la matriz de las derivadas segundas respecto a los coeficientes.

La primera dificultad práctica de estimación de un modelo logit multinomial surge al considerar que variables explicativas usar. Al tener que estimar p modelos, cabe que ocurra que una determinada variable exógena permite predecir la probabilidad que sea $Y = j$, pero que esta variable no sea explicativa en el modelo para predecir la probabilidad que sea $Y = j^*$.

Para estudiar los efectos marginales de las variables exógenas sobre la endógena, Y , hay que calcular las derivadas parciales en cada uno de los p modelos estimados, siendo

$$u_j = \beta_{0j} + \beta_{1j} x_1 + \beta_{2j} x_2 + \dots + \beta_{kj} x_k = \vec{\beta}_j' \vec{x}$$

Así pues, se tiene

$$\frac{\partial \hat{y}_j}{\partial x_i} = \frac{dF}{du_j} \frac{\partial u_j}{\partial x_i} = f(\beta_{0j} + \beta_{1j}x_1 + \beta_{2j}x_2 + \dots + \beta_{kj}x_k) \beta_{ij}$$

es decir, el efecto marginal de x_i para estimar la probabilidad que sea $Y = j$ es proporcional al coeficiente β_{ij} de la variable x_i y del mismo signo, pues $f(u) \geq 0, \forall u$. Por lo tanto, dentro de cada una de las p ecuaciones, cabe comparar los coeficientes de regresión en la misma forma que se hizo en los modelos logit binarios.

Como estos efectos marginales son variables en función de los posibles valores de las variables explicativas, una forma en la que, a veces, se presentan los resultados es calcular la media aritmética de los efectos marginales sobre cada uno de los n casos que han servido para estimar las p ecuaciones del modelo logit multinomial; así, los efectos marginales de la variable explicativa x_i sobre la alternativa j de la variable y , calculada sobre los n elementos de la muestra, se obtiene mediante

$$\frac{\partial \hat{y}_{jt}}{\partial x_i} = f(\hat{\beta}_{0j} + \hat{\beta}_{1j}x_{1t} + \hat{\beta}_{2j}x_{2t} + \dots + \hat{\beta}_{kj}x_{kt}) \hat{\beta}_{ij} \quad t = 1, 2, \dots, n$$

y, el efecto marginal medio de x_i sobre la alternativa j es

$$\frac{\partial \bar{\hat{y}}_{j\cdot}}{\partial x_i} = \frac{1}{n} \sum_{t=1}^n \frac{\partial \hat{y}_{jt}}{\partial x_i}$$

Es posible comparar los valores relativos de los efectos marginales de dos variables en la estimación de la probabilidad que sea $Y = j$, x_i y x_{i^*} , pues

$$\frac{\frac{\partial \hat{y}_j}{\partial x_i}}{\frac{\partial \hat{y}_j}{\partial x_{i^*}}} = \frac{\beta_{ij}}{\beta_{i^*j}}$$

Una cuantificación media del efecto marginal de la variable x_i sobre la probabilidad de ser $Y = j$ se obtiene mediante la expresión

$$\frac{\partial \hat{y}_j}{\partial x_i} = \hat{y}_j \left(\beta_j - \sum_{j^*=1}^p \hat{y}_{j^*} \beta_{j^*} \right)$$

Es frecuente que en estos modelos se usen como variables explicativas, algunas de tipo no numérico. En ese caso, los coeficientes de regresión de cada ecuación están directamente relacionados con los ratios de posibilidades (*odds ratios*) Ψ .

Sea un modelo con una única variable exógena, X , que toma los valores $0, 1, 2, \dots, r$. Si se toma el valor $X = 0$ como referencia, se definen r variables artificiales, x_1, x_2, \dots, x_r , de tal forma que la variable x_i toma el valor 1 si $X = i$, y 0 en los demás casos (por lo que todas las variables artificiales toman el valor 0 para cada caso en el que sea $X = 0$).

Se estiman los p modelos

$$\hat{y}_j = F(\vec{\beta}_j \vec{x}) = P[Y = j | \vec{x}] = \frac{e^{\vec{\beta}_j \vec{x}}}{1 + \sum_{i=1}^p e^{\vec{\beta}_i \vec{x}}} \quad j = 1, 2, \dots, p$$

en el que el vector $\vec{x}' = (1, x_1, x_2, \dots, x_r)$ se define (para cada caso) en función del valor de la variable exógena X .

Los ratios de posibilidades, para $i = 1, 2, \dots, r$, y $j = 1, 2, \dots, p$

$$\psi_j(X = i; X = 0) = \frac{\frac{P[Y = j | X = i]}{P[Y = 0 | X = i]}}{\frac{P[Y = j | X = 0]}{P[Y = 0 | X = 0]}} = \frac{\frac{\hat{y}_j(i)}{\hat{y}_0(i)}}{\frac{\hat{y}_j(0)}{\hat{y}_0(0)}} = e^{\beta_{ij}}$$

son medidas de asociación entre la variable X y la Y . Su logaritmo coincide con el coeficiente de regresión (en el modelo j -ésimo) de la variable artificial x_i . Su interpretación es inmediata: por ejemplo, si $\psi_j(1, 0) = 2$, la proporción de casos en los que es $Y = j$ respecto a los que es $Y = 0$, es el doble en el subconjunto de casos en el que es $X = 1$, respecto a los casos en los que es $X = 0$.

Para determinar los ratios de posibilidades, ψ_j en los que se compara el subconjunto de casos en los que es $Y = j$ respecto al subconjunto en el que es $Y = s$ (en lugar de ser $Y = 0$, como en la expresión anterior) cabe proceder a partir de los modelos estimados, pues

$$\ln \psi_j = \beta_{ij} - \beta_{is}.$$

Estos ratios son útiles si no hay demasiadas categorías tanto en la variable Y como en la X .

Si hay más de una variable exógena no numérica, el número de ratios que se pueden calcular crece con rapidez.

En el caso de usar otra codificación para las variables artificiales, tomando como punto de referencia un valor medio, las estimaciones de los coeficientes varían en una constante, aunque los resultados son idénticos.

Un caso especial son los modelos logit ordinales. En este caso, la variable endógena, y , es no numérica y ordinal. De nuevo, se puede considerar que existe una variable latente, U , cuyos valores determinan el valor j que toma y . Es decir, $y = 0$ si $U \leq \alpha_1$, $y = 1$ si $\alpha_1 < U \leq \alpha_2, \dots$, e $y = p$ si $\alpha_p \leq U$.

Los modelos linealizados se pueden expresar, en forma general, mediante

$$g(\hat{y}_j) = \alpha_j + \vec{\beta}_j' \vec{x}$$

siendo $\hat{y}_j = P(Y = j | \vec{x})$. Las funciones de enlace $g(\cdot)$ más usuales son la logística

$$g(\hat{y}_j) = \ln \frac{\hat{y}_j}{1 - \hat{y}_j}$$

o la probit

$$g(\hat{y}_j) = \Phi^{-1}(\hat{y}_j)$$

Si los ratios de posibilidades o ventajas entre las $p + 1$ categorías son uniformes, esto es, no dependen de los denominados 'puntos de enlace', α_j , el modelo logístico es adecuado. Este modelo se conoce con el nombre de 'ventajas proporcionales' (*proportional odds*).

4.3. Métodos basados en técnicas de Inteligencia Artificial

Los métodos basados en técnicas de IA que se han aplicado a problemas de predicción de *ratings* a largo plazo, tanto de emisiones de activos como de empresas e instituciones se basan en el uso de Redes Neuronales Artificiales (RNA).

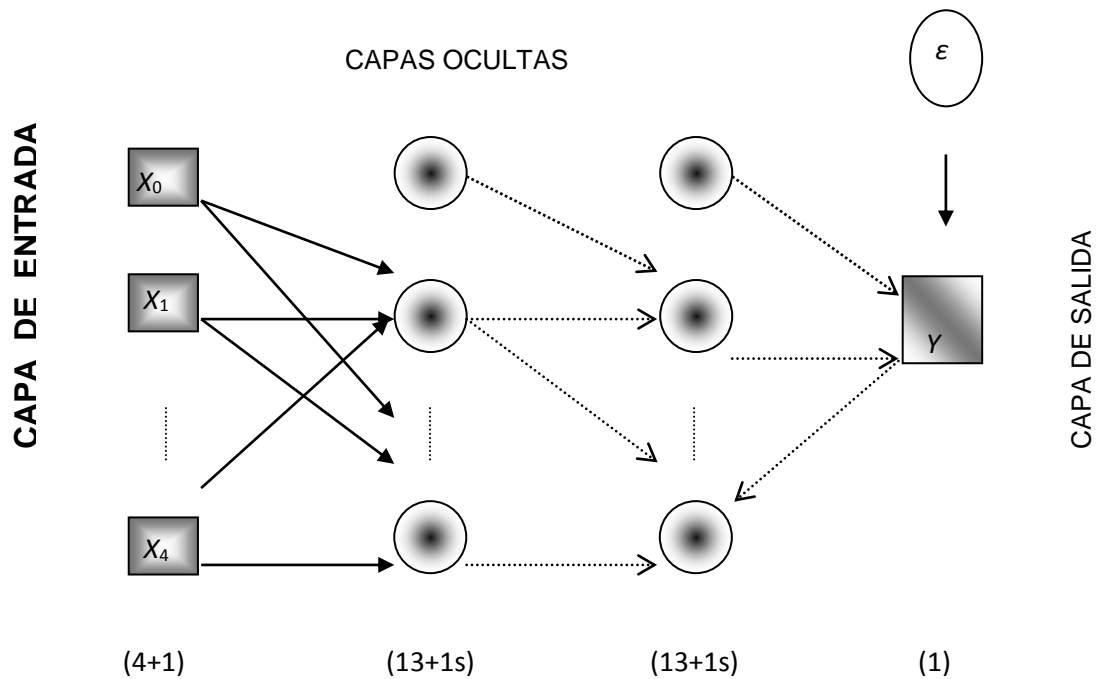


Figura 4.1 Esquema de una RNA de tipo 5:14s:14s:1

Una red neuronal consiste en un conjunto de elementos o unidades de proceso de información, interconectadas, formando un sistema para ajuste de modelos no lineales (Kruse *et al*, 2013), (Smith, 1993). A partir de unas variables de entrada (exógenas o

causales), x_1, x_2, \dots, x_k , se trata de explicar las variaciones de las variables de salida (endógenas o respuesta), y_1, y_2, \dots, y_g , de forma similar a como se especificaría un modelo no lineal multiecuacional (si $g > 1$) o uniecuacional (si $g = 1$):

$$y_h = m_h(x_1, x_2, \dots, x_k) + \varepsilon_h \quad h = 1, 2, \dots, g$$

La dependencia de las variables de salida respecto de las de entrada se formula mediante unas variables no observables, denominadas *neuronas*, con una estructura en una o varias capas según se muestra en el diagrama causal siguiente, en la que hay 5 variables de entrada y una de salida, y dos capas ocultas con 14 neuronas cada una, además del término error ε o perturbación aleatoria de la red.

La información de las variables x_1, x_2, \dots, x_k se transmite a las variables no observables de la primera capa; a su vez, éstas procesan la información recibida (mediante unas funciones que dependen de unos parámetros a estimar) y trasladan la información procesada a las variables de la segunda capa: el proceso continua hasta alcanzar las variables y_1, y_2, \dots, y_g ; la información finalmente obtenida son estimaciones $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_g$.

Las variables de entrada se suelen someter a un cambio de escala, para que tomen valores en el intervalo $[0, 1]$ o en el $[-1, 1]$. Las transformaciones más usuales son la logística o sigmoideal, y la tangente hiperbólica, ambas sobre los datos tipificados. También son frecuentes procesos de normalización, restando el dato mínimo de una variable y dividiendo por el rango, o incluso una normalización corregida, multiplicando por dos el dato normalizado y restándole la unidad.

Las *capas ocultas* están formadas por las variables no observables o neuronas, que incorporan un sistema muy simple de procesamiento de la información de entrada y de obtención de la de salida. El esquema de una neurona aparece en la figura siguiente.




Figura 4.2 Esquema del proceso de información en una neurona


IV. MÉTODOS ESTADÍSTICOS DE CLASIFICACIÓN PARA RATINGS

Los r valores de entrada a la neurona son refundidos mediante la *función de entrada neta*

$$u = w_0 + \sum_{s=1}^r w_s x_s^*$$

en la que la constante w_0 se denomina *parámetro de sesgo* (o *bias*).

Esta entrada neta u es procesada mediante la función de activación, $a = a(u)$, la cual determina que debe hacerse con la entrada; por ejemplo, puede ignorarse el valor estimado u , por no haber alcanzado un valor umbral necesario para desencadenar una información de salida de la neurona, o, simplemente puede ser $a(u) = u$, es decir, la función identidad.



La *información de salida* de la neurona, calculada mediante la función $a(u)$ es enviada a todas las neuronas de la capa siguiente (oculta, o la final de salida). Esta información es procesada mediante una función, F , monótona creciente de u o de $a(u)$, y generalmente toma valores en el intervalo $[0,1]$, siendo la salida

$$y^* = F(a(u))$$

Algunas funciones que tienen estas propiedades son las funciones de distribución de variables aleatorias. Por ejemplo, las funciones de activación más usadas son las siguientes:

- la logística o sigmoidal, que toma valores en el intervalo $(0, 1)$,

$$F(a) = \frac{1}{1 + e^{-a}}$$

- la función de distribución $N(0, 1)$, distribución cuya varianza es menor que la función de distribución logística anterior,

$$F(a) = \Phi(a) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^a e^{-t^2/2} dt$$

- la tangente hiperbólica (que toma valores en el intervalo $[-1, 1]$,

$$F(a) = \tanh a = \frac{e^a - e^{-a}}{e^a + e^{-a}}$$

- la función identidad (en el intervalo $(0, 1)$)

$$F(a) = a$$

y algunas variantes de éstas. Si la variable de salida es no numérica, se suele usar la función logística, e incluso transformar los valores de ésta en los posibles valores de la variable de salida (por ejemplo, en un problema de clasificación). Muchas magnitudes económicas o financieras tienen un comportamiento similar a la forma de la función logística: por ejemplo, una pequeña variación en los tipos de interés tienen poca influencia en la adquisición de un auto, si los tipos son muy bajos o muy altos, pero su efecto es mayor para tipos intermedios.

Así pues, en la entrada de la red, las variables x_1, x_2, \dots, x_k , generan la *entrada neta* a la neurona j -ésima de la primera capa oculta

$$u_{j1} = w_{0j1} + \sum_{s=1}^k w_{sj1} x_s \quad j = 1, 2, \dots, r_1$$

siendo r_1 el número de neuronas en esta primera capa oculta. La neurona j -ésima genera la salida

$$y_{j1} = F(a_{j1}(u_{j1})) = x_{j1}$$

que actúa como entrada a cada una de las r_2 neuronas de la segunda capa oculta (junto con las salidas de las otras neuronas de la primera capa). Así pues, la entrada neta a la neurona i -ésima de la segunda capa oculta es

$$u_{i2} = w_{0i2} + \sum_{s=1}^{r_1} w_{si2} x_{s1} \quad i = 1, 2, \dots, r_2$$

Esta neurona origina la *salida*

$$y_{i2} = F(a_{i2}(u_{i2})) = x_{i2}$$

la cual servirá de entrada a las neuronas de la siguiente capa. Finalmente se llega a la última capa oculta, c , cuyas salidas se transmiten a las variables respuesta, y_1, y_2, \dots, y_g . Así, la entrada neta a la variable endógena h -ésima es

$$\hat{y}_h = w_{0hc} + \sum_{s=1}^{r_c} w_{shc} x_{sc} \quad h = 1, 2, \dots, g$$

Recorriendo hacia atrás la red, los valores estimados de las variables de salida son funciones no lineales de las variables de entrada; una vez especificada la forma o topología de la red, estas funciones quedan perfectamente determinadas, y son función de los parámetros w asociados a todas las capas de la red, función que aunque compleja, puede ponerse en forma explícita.

El número de parámetros aumenta con el número de capas ocultas, que rara vez son mas de dos, y del número de neuronas o variables no observables de cada capa. Por ejemplo, una red con cinco variables de entrada, x_1, x_2, x_3, x_4, x_5 , una variable de salida, y , y dos capas ocultas de 10 y 4 neuronas respectivamente, tendría 60 parámetros en las conexiones entre la capa de entrada y la primera capa oculta, 44 entre la primera y segunda capas ocultas, y 5 en la salida, es decir, un total de 111 parámetros a estimar. Esta red se representa mediante la expresión MLP (5×10×4×1) es decir, con el número de variables (observables o neuronas) en cada capa, incluyendo las de entrada y salida.

Con una red neuronal con dos capas ocultas y funciones de activación no lineales, es posible aproximar funciones no lineales, sin que, a diferencia de los métodos de regresión, haya que especificar a priori la forma funcional. Este resultado teórico justifica el empleo de redes en problemas de ajuste no lineal.

Con respecto a la estimación de los parámetros o pesos de la red, en primer lugar hay que resaltar que será necesario un número n elevado de datos

$$(y_{1t}, y_{2t}, \dots, y_{gt}, x_{1t}, x_{2t}, \dots, x_{kt}) \quad t = 1, 2, \dots, n$$

Además, como el objetivo de la red es poder predecir los valores de las variables de salida a partir de los correspondientes de las variables de entrada, no conviene usar todos los datos disponibles para estimar los pesos w o parámetros, ya que es necesario medir la capacidad predictiva de la red utilizando datos de todas las variables que no hayan sido usados en el proceso de estimación de los parámetros. Así pues el conjunto de n datos disponibles se divide en dos partes: m datos elegidos al azar entre los n se

usan para estimar los pesos, y los $n - m$ restantes se emplean para medir la capacidad predictiva de la red, mediante diversos métodos, como los diagrama predicción-realización, índices de Theil, error cuadrático medio de predicción, etc. El primer grupo de m datos se denomina *conjunto de entrenamiento*.

Al especificar una red, no conviene usar demasiadas capas ocultas ni demasiadas neuronas, pues esto originará un mejor ajuste del modelo a los datos, debido a disponer de más parámetros, pero el precio a pagar será un menor poder predictivo de la red para estimar las variables de salida.

La estimación de los pesos o parámetros de la red se realiza mediante un proceso iterativo. En el instante inicial se asignan unos valores cualesquiera a los pesos de la red, y se estiman las variables de salida. El error que se produce en cada una de ellas con todos los datos

$$e_{ht} = y_{ht} - \hat{y}_{ht} \quad h = 1, 2, \dots, g; \quad t = 1, 2, \dots, n$$

origina una medida de discrepancia, como por ejemplo, el error cuadrático medio, que debe ser disminuida mediante una modificación de los pesos de las distintas capas de la red; en primer lugar se modifican los pesos de la última capa oculta, y a continuación los de la anterior, y así sucesivamente hasta llegar a la capa de las variables de entrada. Este proceso de modificación o aprendizaje hacia atrás es iterativo, y se realiza mediante expresiones como la siguiente, correspondiente a la última capa y a las ponderaciones correspondientes a y_h .

$$\Delta w_{hjc}(i) = \eta \delta_{hc} + \alpha \Delta w_{hjc}(i-1)$$

siendo

$$\delta_{hc} = e_h \text{grad}(u_{hc})$$

En el proceso i -ésimo se modifican las ponderaciones en función del error de predicción, del gradiente de la función de salida y de la última variación de estas ponderaciones en la iteración anterior. La modificación de los pesos en las capas anteriores a la última se realiza de forma similar tomando, para la capa l -ésima

$$\delta_{il} = \text{grad}(u_{il}) \sum_{s=1}^{r_{l+1}} \delta_{s,l+1} w_{sl,l+1}.$$

Generalmente el conjunto de datos para estimar una red, se divide en dos partes: la primera llamada *conjunto de entrenamiento*, formada por el conjunto de valores sobre los que se estiman los parámetros de la red, y la segunda constituye el *conjunto de prueba*, sobre el que se mide el poder predictivo de la red (para estimar las variables endógenas a partir de datos que no han servido para estimar los propios parámetros de la red).

La constante $\eta \in (0,1)$, está asociada a la velocidad de aprendizaje o de adaptación de la red para corregir los errores de predicción cuando se están estimando las ponderaciones, es decir, en la fase de *entrenamiento* de la red. La constante $\alpha \in (0,1)$ trata de establecer una inercia en las variaciones de las ponderaciones para evitar oscilaciones excesivas en iteraciones sucesivas; de esta forma se evita que la función que mide el error de predicción de la red, al disminuir en una iteración, caiga en un mínimo local. Un valor $\eta = 0.1$ es habitual, así como $\alpha = 0.9$. No conviene que ambas constantes tomen simultáneamente valores altos. El tiempo necesario para estimar las ponderaciones puede ser elevado; generalmente los programas de ordenador permiten interrumpir el período de entrenamiento después de un cierto tiempo.

En relación a la *topología de una red*, es decir, a la forma en que se estructuran las distintas capas y sus conexiones, existen diversos tipos de redes. En el desarrollo anterior se ha utilizado una red tipo *perceptrón multicapa*¹, es decir formada por una capa de entrada, una de salida y una o varias capas ocultas, siendo las conexiones entre una capa y la siguiente, como se ha empleado en la estimación de *ratings*. Otra topología consiste en conectar cada capa con todas las capas posteriores; así, si la capa de entrada está directamente conectada a la de salida, la red puede detectar efectos lineales. La red de Jordan (1986) permite retroalimentación de las variables de una capa consigo misma y con variables de capas anteriores y la de Elmer y James (2012) introduce un modelo híbrido de redes con lógica difusa; es útil en modelos recursivos y para analizar series temporales. En algunas redes se usan distintas funciones de activación en distintas capas, e incluso en conjuntos distintos de variables de la misma

¹ El **perceptrón multicapa** es una [red neuronal artificial](#) (RNA) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del [perceptrón](#) (también llamado perceptrón simple). El perceptrón multicapa puede ser totalmente o localmente conectado. En el primer caso cada salida de una neurona de la capa "i" es entrada de todas las neuronas de la capa "i+1", mientras que en el segundo cada neurona de la capa "i" es entrada de una serie de neuronas (región) de la capa "i+1".

capa oculta, con el objetivo de extraer información distinta y transmitirla a las capas posteriores. En las redes de Kohonen no existen variables de salida, y por lo tanto el objetivo no es construir un modelo, sino buscar similitudes entre los casos, de cara a una clasificación similar al análisis de conglomerados.

Las redes neuronales pueden aplicarse como una alternativa a los procesos de modelización uni y multivariante. La ventaja principal es que no es necesario formular explícitamente la forma funcional que relaciona las variables de entrada o exógenas con las de salida, pues en el proceso de aprendizaje, los pesos se van estimando obteniéndose un ajuste que se ajusta a no linealidades. Como inconveniente se puede citar la dificultad de interpretar económicamente los valores estimados para los coeficientes; además es necesario disponer de un número de datos elevado para estimar estas ponderaciones o parámetros para conseguir que sean estables y se puedan aplicar para predecir la variable endógena. Además las redes se emplean en otros campos, como el reconocimiento de formas y en la clasificación, como alternativa a otros métodos multivariantes.




Figura 4.3 Curva ROC

Algunos programas de ordenador (como SPSS) presentan, para evaluar los resultados, diversos gráficos, como la curva ROC (*Receiver Operating Characteristic*), Fawcett (2003), para cada variable dependiente no numérica, y el área bajo ésta. Si la variable y tiene más de dos categorías, cada curva trata el valor de esta categoría frente a todas las demás agrupadas. Al variar el punto de corte para decidir si se estima el valor de la variable o no, se van alterando las estimaciones correctas e incorrectas; la proporción de

falsos negativos se representa en el eje de abscisas, y la de falsos positivos, en el de ordenadas. El área entre la curva y la diagonal asociada a una capacidad predictiva nula (predicción al azar) es una medida del poder predictivo de la red.

La Curva de Ganancias Acumuladas presenta un gráfico para cada categoría de la variable dependiente.




Figura 4.4 Curva ROC.

Fuente: SPSS 23 Manual

Por ejemplo, en el gráfico anterior, al tomar la abscisa 10%, la curva verde muestra una ordenada del 30%, y se obtienen las estimaciones de PD de todos los casos analizados, el 10% de los casos con mayores PD contienen el 30% de todos los casos para los que $y = 1$. La diagonal del cuadrado muestra la situación de incertidumbre respecto a la clasificación. Esta curva puede servir para tomar como punto de corte para la clasificación un valor $c \neq 0.5$, que es el que utiliza por defecto, en función de la ganancia que se desea (lo que dependerá de los errores de clasificación de tipo I y II). Se utilizan en su cálculo todos los datos, incluyendo los del conjunto de prueba.

Se muestran también los valores estimados de y con los valores de y , y si la variable dependiente es categórica, para cada valor de y se muestra un diagrama de caja para los valores estimados de y (o probabilidades estimadas de este valor).

Para cada variable explicativa se realiza un análisis de sensibilidad, evaluando la *importancia* de cada variable explicativa en la red. Indican como cambia la variable y estimada al variar las variables explicativas. La *importancia normalizada* se obtiene dividiendo la importancia por su valor máximo.

Otro tipo de red neuronal de uso frecuente es la red denominada RBF (*Radial Basis Function*). Se procesan inicialmente las variables de entrada mediante una única combinación lineal

$$u = w_0 + \sum_{s=1}^k w_s x_s$$

y esta información es procesada en cada neurona mediante una transformación Normal, pero con medias distintas para cada neurona, y la función de activación es la distancia entre los valores de entrada a la media correspondiente. Estas redes RBF solo tienen una capa oculta. Mediante una red MLP puede aproximarse una RBF, aunque, como señalan Mandic y Chambers (2001), el recíproco no siempre es posible.

Los primeros modelos de redes neuronales se desarrollan en los años cuarenta por los neurólogos McCulloch y Pitts. En 1949, Donald Hebb desarrolló sus ideas sobre el aprendizaje neuronal. En 1958, Roseblatt desarrolló el perceptrón, y en 1960, Widrow y Hoff desarrollaron la primera aplicación industrial real. En los años 80, volvieron a resurgir las redes gracias al desarrollo de Hopfield, y al algoritmo de aprendizaje de retropropagación (BackPropagation) de Rumelhart y McLellan en 1986 que fue aplicado en el desarrollo de los perceptrones multicapa.

La crítica más usual al uso de redes neuronales es la falta de interpretabilidad de los pesos o parámetros estimados, además de la utilización de un número elevado de éstos, lo que resta generalidad al modelo. En realidad, si el objetivo es predecir una variable endógena, sin pretender explicar o interpretar la forma funcional definida, es justificable el uso de redes. Lógicamente, se precisa un número elevado de datos.

El programa SPSS de IBM Corp. es el que se ha usado en este trabajo, en su versión 26. Incluye módulos de regresión logística, de análisis discriminante y de estimación de modelos de redes neuronales.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

5.1. Material estadístico disponible

5.2. Distribución de los ratings

5.3. Análisis de variables explicativas y ratios

5.4. Modelos basados en técnicas multivariantes

5.5. Modelos basados en RNA

5.6. Resumen de resultados

5.1. Material estadístico disponible

Se han seleccionado dos muestras; la primera formada por $n = 1111$ empresas, mediante una selección aleatoria en la base de datos Bloomberg, para estudiar la relación entre varias variables económico financieras que se pueden obtener en el mercado, es decir, públicas, con los *ratings* atribuido por dos de las principales agencias de valoración: S&P's y Moody's.

El conjunto lo forman 1111 compañías de las que se disponen datos durante los años 2014 a 2018. En total 5555 de los cuales 3750 constan de casos con todos los datos completos.

Los principales tipos de variables que se pueden obtener de los estados financieros públicos de estas compañías son:

1. Variables basadas en el tamaño: total balance, activos fijos, total deuda, ventas, fondos propios.
2. Variables basadas en la actividad: beneficio antes de intereses, impuestos, depreciaciones y amortizaciones (EBITDA), beneficio antes de intereses e impuestos (EBIT), flujos de caja de las actividades ordinarias/operativas (CFO), flujos de caja de las actividades ordinarias sin contar con las variaciones de circulante (FFO), gastos financieros netos, gastos financieros netos sobre ventas totales, dividendos, gastos operativos o *capex*.
3. Variables basadas en el apalancamiento: flujos de caja de las actividades ordinarias sobre deuda total, deuda total sobre balance total, deuda total sobre fondos propios, deuda total a largo plazo sobre fondos propios, deuda total sobre deuda total más fondos propios, y fondos propios más deuda total a largo plazo sobre activos fijos.

4. Variables basadas en la liquidez: pasivo sobre tesorería, activo circulante sobre pasivo circulante, activo circulante sobre ventas, fondo de maniobra, fondo de maniobra sobre ventas, activo circulante sobre total balance.
5. Variables basadas en la rentabilidad: EBITDA sobre ventas, EBIT sobre ventas, beneficio neto sobre ventas, beneficio neto sobre balance total (ROA), beneficio neto sobre fondos propios (ROE), beneficios por acción (EPS).
6. Variables basadas en el mercado: capitalización, *credit default swap* a 5 años (CDS 5y).
7. Variables de crecimiento de ventas, beneficios y capitalización bursátil en los últimos cinco años.

La variable de tamaño más utilizada en problemas de predicción de *rating* es el total de activos de las empresas (Horrigan, 1966; Kaplan y Urwitz, 1979; Pinches y Mingo, 1973; Maher y Sen, 1997; Huang et al., 2004). También se han utilizado como variables de tamaño el monto de la emisión (Pinches y Mingo, 1973), el total de ventas (Surkan y Singleton, 1990), el total del capital (Horrigan, 1966; Kaplan y Urwitz, 1979; Maher y Sen, 1997; Huang, Chen, et al., 2004) y el total de la deuda corporativa (Chaveesuk, et al., 1999; Huang et al., 2004). Kim y Ahn (2012) utilizan unas técnicas de modelización denominadas 'vector machines' o máquinas de soporte vectorial, también utilizada por Rovira et al. (2005).

El tamaño de una compañía está vinculado con la capacidad de afrontar crisis financiera, es decir, a mayor tamaño de la compañía, mayor capacidad de afrontar los ciclos económicos y por lo tanto mayor debería ser la calificación crediticia. Un evidencia que apoya esta creencia se encuentra en Huang et al. (2004), quienes midieron la contribución que hacían las variables en la predicción de *rating*, concluyendo que las variables que tenían mayor poder predictivo para su muestra de datos de EUA fueron dos variables de tamaño (total activo y total pasivo) y una de financiación (total deuda de largo plazo sobre el total capital pagado).

Las variables de actividad regularmente hacen referencia a las ventas de las compañías, ya sea como un cociente o como una tasa de crecimiento (Horrigan, 1966; Dutta y Shekhar, 1988, Surkan y Singleton, 1990). Todas las variables de actividad intentan capturar la velocidad de las operaciones, como por ejemplo la carga de intereses pagados respecto de los gastos totales o las ventas totales (Kaplan y Urwitz, 1979; Shin y Han, 2001). La relación entre el *rating* y el nivel de actividad es importante ya que este tipo de ratios indica el ritmo de actividades que tiene la compañía, es decir, si los proyectos que ésta tiene le permiten el adecuado pago de sus compromisos.

Las variables relacionadas con la financiación de las compañías suelen referirse a la proporción entre la deuda (de corto o largo plazo) y el total activo (Shin y Han, 2001; Dutta y Shekhar, 1988, Chaveesuk et al., 1999) o entre la deuda y el patrimonio (Kaplan y Urwitz, 1979; Huang et al., 2004). También es frecuente el uso de ratios de liquidez compuestas por el activo circulante y/o el pasivo circulante. En este tipo de ratios, se utilizan cocientes o diferencias entre ambos componentes del circulante o como proporción del capital o del activo (Chaveesuk et al., 1999; Dutta y Shekhar, 1988). En otros enfoques (Mushang y Sin-Jin, 2014), se han utilizado algoritmos genéticos para determinar los *rating*, o métodos '*double ensemble*' como el de Kwon et al. (2013). Bongaerts (2014) analiza el papel de las agencias de *rating* y las alternativas para evaluar el riesgo.

La finalidad de las ratios de liquidez es capturar información de la compañía que indique si su situación financiera para enfrentar el pago inmediato de sus obligaciones es apropiada o no, y como es la estructura de financiación.

Otras ratios usados para predecir el *rating* miden la rentabilidad que obtiene la compañía en un período de tiempo. Estas ratios miden la eficiencia, a través de partidas del mismo Estado de Resultados (Horrigan, 1966; Pinches y Mingo, 1973; Dutta y Shekhar, 1988; Huang, Chen, et al., 2004), o bien, respecto de los montos invertidos en la compañía (Surkan y Singleton, 1990; Kaplan y Urwitz, 1979).

La volatilidad de los precios accionarios de la compañía evaluada es otro elemento que se ha incluido en este tipo de aproximaciones (Kaplan y Urwitz, 1979; Maher y Sen, 1997). Su objetivo es medir el grado de incertidumbre que el mercado percibe y materializa en la cotización bursátil de las acciones de la compañía. Sin embargo, este tipo de variables también puede incluir efectos distintos a la calidad crediticia, y que tengan más relación con las fluctuaciones propias del mercado de capitales. Las redes neuronales se han empleado en numerosos trabajos en la última década, existiendo precedentes en España, aunque la mayor parte de los trabajos están vinculados a instituciones asiáticas y a revistas relacionadas con la inteligencia artificial (Franck, 2009, Zhao et al., 2014, Tsai et al., 2008).

Las estimaciones de Moody's con el modelo KMV y las de S&P's para evaluar la probabilidad de fallido aparecen en la tabla siguiente.

MKMV	S & P	PD [%]
Aaa	AAA	0.02
Aa	AA	0.03
A	A	0.07
Baa	BBB	0.18
Ba	BB	0.7
B	B	2.0
Caa	CCC	14.0
Ca	CC	17.0
C	C	20.0
D	D	> 20.0

Tabla 5.1 Probabilidades de fallido asociada a distintos niveles de *rating*

Fuente: Moody's y S&P's

La elaboración de modelos para predecir el *rating* de una compañía requiere estudiar las posibles variables exógenas que tengan capacidad predictiva. Varios autores, entre los que cabe citar a Jayadev (2006), se basan en ratios financieros. Vamos a partir de

distintas variables, y a partir de éstas se elaboran ratios. Posteriormente se usarán en los modelos ambos tipos de variables explicativas, así como algún factor, como el sector al que pertenece la compañía. Dada la cantidad de variables que se pueden utilizar para replicar el *rating* de una compañía, se han seleccionado las siguientes variables financieras:

Las variables financieras básicas utilizadas son las siguientes:

- X1 = Ventas: ventas o ingresos.
- X2 = EBITDA: beneficio antes de intereses, impuestos, depreciaciones y amortizaciones.
- X3 = EBIT: beneficio antes de intereses e impuestos.
- X4 = Gastos financieros netos.
- X5 = Beneficio neto: beneficio neto.
- X6 = Total del activo en el balance.
- X7 = Activos no corrientes.
- X8 = Existencias.
- X9 = Caja e inversiones temporales a corto plazo.
- X10 = Deuda total (largo y corto plazo).
- X11 = Fondos propios.
- X12 = Flujos de caja operativos.
- X13 = Gastos operativos (es negativo al tratarse de un gasto).
- X14 = Dividendos (es negativo al tratarse de un gasto).
- X15 = Capitalización bursátil.

Todas ellas expresadas en millones de euros.

Algunas de estas variables son utilizadas por las empresas de valoración de forma clara, como el tamaño de cada empresa, pues en los niveles de *rating* más elevados no se encuentran empresas de tamaño medio o bajo.

A partir de estas variables, es posible elaborar algunos índices económico-financieros usuales

$$R1 = \text{Margen EBITDA} = X2/X1$$

$$R2 = \text{Margen EBIT} = X3/X1$$

$$R3 = \text{Margen de beneficio neto} = X4/X1$$

$$R4 = \text{Cobertura de intereses} = X2/X4$$

$$R5 = \text{Ratio de deuda} = \text{Deuda}/(\text{Deuda} + \text{Fondos Propios}) = X10/(X10 + X11)$$

$$R6 = \text{Deuda neta/EBITDA} = (X10 - X9)/X2$$

$$R7 = \text{Autonomía financiera} = X11/X7$$

$$R8 = \text{Deuda neta/CF0} = X10/X12$$

$$R9 = \text{Flujos} = X12 + X13 + X14$$

También se dispone de tres variables asociadas al crecimiento de las ventas, los beneficios y la capitalización bursátil en los últimos cinco años.

Además, se dispone de una segunda muestra con datos de 2010 a 2014, también obtenida en las bases de datos de Bloomberg, y formada por $n = 1324$ empresas de distintos sectores.

Con esta muestra, independiente de la primera, se han realizado los cálculos para realizar comparaciones entre los años 2014 y 2018.

Las variables correspondientes a esta segunda muestra son las 15 contenidas en la primera muestra, a partir de las cuales se obtienen los ratios económico-financieros utilizados.

5.2. Distribución de los *ratings*

Las variables que se pretenden predecir son las de calificación elaboradas por las dos empresas de *rating* consideradas

$$Y1 = \text{S\&P's}$$

$$Y2 = \text{Moody's}$$

variables que son ordinales, aunque en su forma de cálculo, las compañías de valoración las estiman numéricamente, y posteriormente las categorizar definiendo una serie de intervalos. En esta puntuación, además de datos económico-financieros de cada empresa, utilizan datos de otra naturaleza, incluyendo opiniones o rumores, y, sobre todo, utilizan el nivel de valoración anterior, hecho éste que ha dado origen a situaciones no previstas, como se ha indicado posteriormente.

Se dispone de las dos muestras antes citadas de más de mil empresas cada una, seleccionadas al azar en diversos sectores económicos de las bases de datos de Bloomberg. Se va a describir la muestra correspondiente al último ejercicio para el que hay datos, 2018, aunque se tienen datos de 15 años, que abarcan el período 2004-2018

En el ejercicio de 2018 se dispone de datos de las $n = 1111$ empresas indicadas para las que se ha observado las variables (X) anteriores correspondientes, de las que se derivan los correspondientes ratios (R). Para cada una de ellas se dispone además de la calificación de S&P's, de la calificación de Moody's, en parte. Pertenecen a distintos sectores económicos, según se aprecia en la tabla siguiente:

	Frecuencia	Porcentaje
Consumo	105	9,5
Energía	91	8,2
Sanidad	73	6,6
Hoteles	21	1,9
Industrial	256	23,0
Informática	126	11,3
Medios	66	5,9
Minería	52	4,7
Papeleras	28	2,5
Químico	46	4,1
Comercial	71	6,4
Telecomunicación	48	4,3
Utilidades	128	11,5
Total	1111	100,0

Tabla 5.2 Composición de la muestra correspondiente a 2018 por sectores

Para la segunda muestra, asociada al año 2014, la distribución por sectores económicos es similar, como se describe en la tabla siguiente.

	Frecuencia	Porcentaje
Consumo	94	7,1
Energía	189	14,3
Sanidad	71	5,4
Hoteles	20	1,5
Industriales	251	19,0
Informática	116	8,8

Medios	52	3,9
Minería	37	2,8
Papeleras	24	1,8
Química	44	3,3
Comerciales	68	5,1
Telecomunicación	86	6,5
Utilidades	272	20,5
Total	1324	100,0

Tabla 5.3 Composición de la muestra correspondiente a 2014 por sectores

Coincidiendo con la primera muestra, los sectores para los que se dispone de más información estadística son los de empresas de bienes de consumo, las energéticas, las industriales, las de informáticas y las denominadas 'utilidades' o servicios básicos.

Los *ratings* disponibles se muestran a continuación, así como una tabla de contingencia para analizar las similitudes y diferencias en las valoraciones de S&P's y Moody's, que serán analizadas con detalle en el capítulo siguiente. En la distribución de los *ratings* es más frecuente encontrar empresas comprendidas entre las categorías A+ hasta BB+, es decir, consideradas como inversiones recomendables (*prime* o de inversión), que empresas peor calificadas denominadas 'especulativas' (*no prime* o *junk*) en las categorías BB o inferiores. Todavía, en las primeras clasificaciones del grupo de especulativas, se han seleccionado bastantes empresas. En los escalones de los grupos C y D, en el mundo real existen menos empresas, pues su mortalidad es elevada, por lo que el número de empresas en ambas muestras es mucho menor. Por otro lado, en las categorías superiores del grupo de inversión, el número de empresas es bastante más reducido, y así se refleja en ambas muestras.

En definitiva, la distribución muestral de las empresas seleccionadas es similar a la distribución en el colectivo de empresas que son valoradas por las grandes agencias de *rating*.

	Frecuencia	Porcentaje	Porcentaje válido
AAA	3	,3	,3
AA+	2	,2	,2
AA	7	,6	,7
AA-	21	1,9	2,2
A+	37	3,3	3,9
A	49	4,4	5,2
A-	94	8,5	9,9
BBB+	139	12,5	14,7
BBB	173	15,6	18,3
BBB-	103	9,3	10,9
BB+	68	6,1	7,2
BB	70	6,3	7,4
BB-	62	5,6	6,5
B+	29	2,6	3,1
B	43	3,9	4,5
B-	21	1,9	2,2
CCC+	11	1,0	1,2
CCC	7	,6	,7
CCC-	2	,2	,2
D	6	,5	,6
Total	947	85,2	100,0
Perdidos	164	14,8	
Total	1111	100,0	

Tabla 5.4 Distribución de las puntuaciones de S&P's en 2018

Para el 14.8% de estas empresas no se dispone de calificación de S&P's.

En el caso de los *ratings* de Moody's, se tiene la distribución siguiente, que es similar a la distribución de las puntuaciones atribuidas por S&P's:

	Frecuencia	Porcentaje	Porcentaje válido
Aaa	3	,3	,4
Aa1	1	,1	,1
Aa2	5	,5	,6
Aa3	10	,9	1,2
A1	35	3,2	4,3
A2	50	4,5	6,2
A3	64	5,8	7,9
Baa1	114	10,3	14,1
Baa2	159	14,3	19,7
Baa3	100	9,0	12,4
Ba1	53	4,8	6,6
Ba2	64	5,8	7,9
Ba3	46	4,1	5,7
B1	36	3,2	4,4
B2	27	2,4	3,3
B3	23	2,1	2,8
Caa1	11	1,0	1,4
Caa2	3	,3	,4
Caa3	1	,1	,1
Ca	4	,4	,5
Total	809	72,8	100
Perdidos	302	27,2	
Total	1111	100	

Tabla 5.5 Distribución de las puntuaciones de Moody's en 2018

En la tabla de frecuencias de las empresas seleccionadas, un 27.2% de las empresas no dispone del *rating* correspondiente de Moody's.

Se dispone, además de dos muestras adicionales para el comienzo del quinquenio considerado, y cuya distribución de *ratings* para las dos agencias de acreditación son similares. Así, la distribución de calificaciones en la segunda muestra, para ambas agencias, se muestra en las tablas siguientes.

	Frecuencia	Porcentaje
AAA	5	,4
AA+	2	,2
AA	13	1,0
AA-	30	2,3
A+	44	3,3
A	74	5,6
A-	122	9,2
BBB+	145	11,0
BBB	184	13,9
BBB-	148	11,2
BB+	119	9,0
BB	119	9,0
BB-	89	6,7
B+	95	7,2
B	71	5,4
B-	37	2,8
CCC+	11	,8
CCC	5	,4
CCC-	6	,5
D	5	,4

Total	1324	100,0
-------	------	-------

Tabla 5.6 Distribución de las puntuaciones de S&P's en 2014

En la muestra del año 2014 se dispone de la calificación de S&P's para todas las empresas, pero no todas las de Moody's.

	Frecuencia	Porcentaje	Porcentaje válido
Aaa	4	,3	,4
Aa1	5	,4	,5
Aa2	5	,4	,5
Aa3	22	1,7	2,0
A1	42	3,2	3,9
A2	66	5,0	6,1
A3	86	6,5	8,0
Baa1	127	9,6	11,8
Baa2	144	10,9	13,4
Baa3	118	8,9	11,0
Ba1	94	7,1	8,7
Ba2	83	6,3	7,7
Ba3	91	6,9	8,4
B1	76	5,7	7,1
B2	48	3,6	4,5
B3	31	2,3	2,9
Caa1	24	1,8	2,2
Caa2	6	,5	,6
Caa3	3	,2	,3
Ca	2	,2	,2

Total	1077	81,3	100,0
Perdidos	247	18,7	
Total	1324	100,0	

Tabla 5.7 Distribución de las puntuaciones de Moody's en 2014

Los *ratings* más frecuentes están en las categorías centrales correspondientes a las inferiores del grado de inversión (desde A/A2 a BBB-/Baa3), y las primeras del grado especulativo (BB+/Ba1 a B/B2), es decir, en aproximadamente la mitad de los niveles de calificación, y en esto coinciden los resultados obtenidos con ambas agencias en las dos muestras. Aunque, como se verá más adelante, la distribución de los *ratings* en los trece sectores empresariales considerados, es bastante heterogénea. En algunos sectores las calificaciones se concentran en los niveles centrales, en otros varían a lo largo de todo el rango de puntuaciones, etc.

El número disponible de empresas con *rating* de Moody's es inferior a las que se manejan con la valoración de S&P's en todas las muestras, lo que es congruente con la cobertura del mercado por parte de las dos agencias.

Para tratar los valores de los *ratings*, se ha procedido a varias codificaciones numéricas que engloben las 20 categorías que van desde AAA (o Aaa) a la D (o Ca)

S&P's	Moody's	Puntuación Y	S&P's	Moody's	S&P's YS	S&P's YSn	Moody's YMn
AAA	Aaa	1	Inversión	Prime1	1	3	5
AA+	Aa1	2	Inversión	Prime1	1	3	5
AA	Aa2	3	Inversión	Prime1	1	3	5
AA-	Aa3	4	Inversión	Prime1	1	3	5
A+	A1	5	Inversión	Prime1	1	3	5

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

A	A2	6	Inversión	Prime12	1	3	4
A-	A3	7	Inversión	Prime12	1	3	4
BBB+	Baa1	8	Inversión	Prime2	1	2	3
BBB	Baa2	9	Inversión	Prime23	1	2	2
BBB-	Baa3	10	Inversión	Prime3	1	2	1
BB+	Ba1	11	Especulativa	No prime	0	1	0
BB	Ba2	12	Especulativa	No prime	0	1	0
BB-	Ba3	13	Especulativa	No prime	0	1	0
B+	B1	14	Especulativa	No prime	0	1	0
B	B2	15	Especulativa	No prime	0	1	0
B-	B3	16	Especulativa	No prime	0	1	0
CCC+	Caa1	17	Especulativa	No prime	0	0	0
CCC	Caa2	18	Especulativa	No prime	0	0	0
CCC-	Caa3	19	Especulativa	No prime	0	0	0
D	Ca	20	Especulativa	No prime	0	0	0

Tabla 5.8 Codificación de calificaciones y codificaciones agregadas

Las categorías de los *ratings* son alfanuméricas ordenadas, tanto para S&P's como para Moody's. Se ha realizado una codificación numérica en las variables

$$Y_S \in \{0,1\} \text{ e } Y_{Sn} \in \{0,1,2,3\} \quad \text{para S\&P's}$$

$$Y_M \in \{0,1\} \text{ e } Y_{Mn} \in \{0,1,2,3,4,5\} \quad \text{para Moody's}$$

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	Consumo	Energía	Sanidad	Hoteles	Industrial	Informática	Medios	Minería	Papeleras	Químico	Comercial	Telecomunicaciones	Utilidades	Total
AAA	0	0	1	0	1	1	0	0	0	0	0	0	0	3
AA+	0	0	0	0	0	2	0	0	0	0	0	0	0	2
AA	0	2	3	0	0	1	0	0	0	0	1	0	0	7
AA-	5	1	3	0	7	2	0	0	0	0	2	1	0	21
A+	7	4	4	0	12	6	0	0	0	0	3	0	1	37
A	7	2	1	0	13	4	0	8	0	4	3	1	6	49
A-	12	5	8	1	19	8	3	2	0	3	3	4	26	94
BBB+	10	5	5	0	28	11	7	4	2	7	5	7	48	139
BBB	17	13	14	2	33	18	10	8	6	9	14	6	23	173
BBB-	9	12	2	3	26	13	4	9	5	6	3	2	9	103
BB+	7	2	6	0	14	17	0	5	7	3	2	5	0	68
BB	3	4	4	2	19	12	8	2	3	2	6	4	1	70
BB-	7	4	3	1	13	5	8	5	3	1	6	2	4	62
B+	3	3	0	5	4	1	1	0	0	4	2	6	0	29
B	1	3	6	1	8	4	6	3	0	0	9	2	0	43
B-	1	4	2	0	8	2	4	0	0	0	0	0	0	21
CCC+	0	6	0	0	2	1	0	0	0	2	0	0	0	11
CCC	1	0	1	0	1	0	1	0	0	0	3	0	0	7
CCC-	0	0	0	0	0	0	0	0	0	0	0	2	0	2
D	1	2	0	0	2	0	0	0	0	0	1	0	0	6

Tabla 5.9 Ratings de S&P's en 2018 por sectores

	Consumo	Energía	Sanidad	Hoteles	Industrial	Informática	Medios	Minería	Papeleras	Químico	Comercial	Telecomunicaciones	Utilidades	Total
Aaa	0	0	1	0	1	1	0	0	0	0	0	0	0	3
Aa1	0	0	0	0	0	1	0	0	0	0	0	0	0	1
Aa2	0	3	0	0	0	1	0	0	0	0	1	0	0	5
Aa3	4	0	1	0	1	2	0	0	0	0	1	1	0	10
A1	9	4	5	0	8	6	0	0	0	0	1	0	2	35
A2	6	1	3	0	17	3	0	8	0	4	4	2	2	50
A3	7	4	4	1	18	8	3	1	0	4	3	3	8	64
Baa1	12	8	8	0	21	7	4	5	0	5	7	5	32	114
Baa2	15	8	11	3	18	16	6	8	6	10	8	7	43	159
Baa3	12	10	5	0	25	13	4	8	5	5	5	0	8	100
Ba1	2	4	3	0	12	9	1	3	7	2	2	6	2	53
Ba2	2	4	5	1	11	11	4	3	6	3	8	6	0	64
Ba3	7	3	3	2	13	6	2	3	0	2	3	2	0	46
B1	4	2	1	4	5	5	2	3	0	2	2	3	3	36
B2	0	5	3	1	5	4	1	0	0	0	5	3	0	27
B3	2	4	4	0	8	1	2	0	0	0	2	0	0	23
Caa1	0	4	0	0	3	0	0	0	0	2	2	0	0	11
Caa2	0	0	0	0	0	0	0	0	0	0	1	2	0	3
Caa3	0	0	0	0	1	0	0	0	0	0	0	0	0	1
Ca	0	0	0	0	3	0	0	0	0	0	1	0	0	4

Tabla 5.10 Ratings de Moody's en 2018 por sectores

Para la muestra de 2014, las distribuciones de *ratings* por sectores son similares.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	Consumo	Energía	Sanidad	Hoteles	Industriales	Informática	Medios	Minería	Papeleras	Química	Comerciales	Telecomunicación	Utilidades	Total
AAA	0	2	1	0	1	1	0	0	0	0	0	0	0	5
AA+	0	0	0	0	1	1	0	0	0	0	0	0	0	2
AA	1	2	4	0	1	2	0	0	0	0	1	1	1	13
AA-	3	6	3	0	5	3	0	0	0	0	2	4	4	30
A+	4	1	6	0	9	4	0	1	0	3	2	2	12	44
A	10	7	2	0	23	6	0	1	0	4	3	2	16	74
A-	8	3	6	0	22	9	1	2	0	2	8	8	53	122
BBB+	13	17	6	1	15	11	8	1	1	9	6	10	47	145
BBB	13	19	6	2	29	14	9	7	5	10	8	13	49	184
BBB-	12	14	9	3	21	16	4	5	3	7	11	4	39	148
BB+	9	14	3	1	30	18	4	7	3	1	5	9	15	119
BB	6	15	8	4	24	15	3	5	7	3	8	8	13	119
BB-	4	12	5	2	28	7	7	3	3	1	3	7	7	89
B+	5	27	7	2	17	7	6	1	1	4	4	7	7	95
B	4	24	4	4	16	1	5	3	0	0	2	6	2	71
B-	1	13	1	1	5	1	3	1	1	0	3	5	2	37
CCC+	1	4	0	0	1	0	2	0	0	0	2	0	1	11
CCC	0	3	0	0	2	0	0	0	0	0	0	0	0	5
CCC-	0	2	0	0	0	0	0	0	0	0	0	0	4	6
D	0	4	0	0	1	0	0	0	0	0	0	0	0	5

Tabla 5.11 Ratings de S&P's en 2014 por sectores

	Consumo	Energía	Sanidad	Hoteles	Industriales	Informática	Medios	Minería	Papeleras	Química	Comerciales	Telecomunicación	Utilidades	Total
Aaa	0	1	1	0	1	1	0	0	0	0	0	0	0	4
Aa1	0	3	0	0	0	2	0	0	0	0	0	0	0	5
Aa2	1	1	0	0	0	1	0	0	0	0	1	0	1	5
Aa3	2	4	1	0	2	0	0	0	0	0	0	5	8	22
A1	6	2	5	0	6	8	0	1	0	1	2	1	10	42
A2	8	5	6	0	22	2	0	0	0	6	3	3	11	66
A3	5	6	3	0	15	6	1	2	0	2	5	5	36	86
Baa1	11	9	4	1	15	10	6	1	0	5	6	7	52	127
Baa2	13	17	9	2	21	12	5	5	5	10	10	9	26	144
Baa3	10	12	9	1	15	12	4	5	2	6	5	4	33	118
Ba1	7	13	5	2	12	9	3	10	3	5	6	11	8	94
Ba2	7	9	4	1	25	10	3	3	5	3	3	2	8	83
Ba3	5	15	5	1	17	13	6	2	5	3	7	4	8	91
B1	5	26	6	0	20	7	2	0	1	1	3	3	2	76
B2	2	14	3	5	11	3	3	0	1	0	0	5	1	48
B3	0	12	0	0	10	0	2	1	0	0	2	3	1	31
Caa1	1	7	1	0	3	0	3	0	0	0	3	3	3	24
Caa2	0	5	0	0	0	0	0	0	0	0	0	1	0	6
Caa3	0	1	0	0	1	0	0	0	0	0	0	0	1	3
Ca	0	2	0	0	0	0	0	0	0	0	0	0	0	2

Tabla 5.12 Ratings de Moody's en 2014 por sectores

En prácticamente todos los sectores, los *ratings* mayoritarios son los de las tres clases BBB, para S&P's y las tres Baa en el caso de Moody's, seguidos de las tres clases A y de las tres primeras clases de tipo especulativo (BB y Ba, para cada agencia). Lógicamente, en las categorías inferiores de *ratings* hay menos empresas (pues sus probabilidades de fallido crecen), y también se encuentran menos empresas en las calificaciones más altas.

En las otras dos agregaciones consideradas, se tienen una distribución de puntuaciones

		S&P's				Total
		D a CCC+	B- a BB+	BBB- a BBB+	A- a AAA	
Sector	Consumo	2	22	36	31	91
	Energía	7	20	30	14	71
	Sanidad	1	21	21	20	63
	Hoteles	0	9	5	1	15
	Industrial	4	66	87	52	209
	Informática	1	41	42	24	108
	Medios	1	27	21	3	52
	Minería	0	15	21	10	46
	Papeleras	0	13	13	0	26
	Químico	2	10	22	7	41
	Comercial	4	25	22	12	63
	Telecomunicaciones	2	19	15	6	42
	Utilidades	0	5	80	33	118
	Total	24	293	415	213	945

Tabla 5.13 Distribución de ratings de S&P's (2018)

		Moody's						Total
		No prime	Prime 3	Prime 2/3	Prime 2	Prime 1/2	Prime 1	
Sector	Consumo	17	12	15	12	13	13	82
	Energía	26	10	8	8	5	7	64
	Sanidad	19	5	11	8	7	7	57
	Hoteles	8	0	3	0	1	0	12
	Industrial	61	25	18	21	35	10	170

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Informática	36	13	16	7	11	11	94
Medios	12	4	6	4	3	0	29
Minería	12	8	8	5	9	0	42
Papeleras	13	5	6	0	0	0	24
Químico	11	5	10	5	8	0	39
Comercial	26	5	8	7	7	3	56
Telecomunicación	22	0	7	5	5	1	40
Utilidades	5	8	43	32	10	2	100
Total	268	100	159	114	114	54	809

Tabla 5.14 Distribución de ratings de Moody's (2018)

Se puede apreciar que algunos sectores tienden a tener una valoración más baja, como en sanidad, en medios de comunicación o en sector comercial (posiblemente debido a la competencia de empresas de ventas en la red), e incluso en el sector de telecomunicaciones.

Sector		S&P's			Moody's		
		Especulativo	Inversión	Total	Especulativo	Inversión	Total
Consumo		24	67	91	17	65	82
Energía		27	44	71	26	38	64
Sanidad		22	41	63	19	38	57
Hoteles		9	6	15	8	4	12
Industrial		70	139	209	61	109	170
Informática		42	66	108	36	58	94
Medios		28	24	52	12	17	29
Minería		15	31	46	12	30	42
Papeleras		13	13	26	13	11	24

Químico	12	29	41	11	28	39
Comercial	29	34	63	26	30	56
Telecomunicación	21	21	42	22	18	40
Utilidades	5	113	118	5	95	100
Total	317	628	945	268	541	809

Tabla 5.15 Distribución por sectores de empresas calificadas como prime-no prime (2018)

Estas variables Y de valoración son las que serán objeto de modelización, y, obviamente, al agregar la calificación en un número inferior de clases, se mejorará el poder predictivo de los modelos. Para conseguir modelizar el conjunto de 20 categorías de *rating* originales con la misma precisión, sería necesario tomar un conjunto de datos mucho más amplio.

Existen más datos de *rating* de S&P's que de Moody's en la muestra considerada, por lo que se ha generado Y a partir de la valoración de la muestra considerada en 2018. De igual forma se procede con la muestra correspondiente a 2014. En la codificación de los *ratings* se ha usado el dígito 1 para representar la máxima calificación crediticia, y el 20 para la peor.

5.3. Análisis de variables explicativas y ratios

En primer lugar se va a proceder a una descripción general de las variables utilizadas en el proceso de modelización, empezando por las económico-financieras (X) y los ratios (R): los estadísticos descriptivos básicos de las primeras son

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

		X1 Ventas	X2 EBITDA	X3 EBIT	X4 Gastos financieros	X5 Beneficio neto	X6 Total Activo	X7 Activos no corrientes	X8 Existencias
n	Válido	929	930	930	870	932	931	927	830
	Perdidos	182	181	181	241	179	180	184	281
Media		18409,14	3258,86	2069,42	316,03	1462,89	32363,85	21369,78	2166,85
Desv. Desviación		32716,726	6167,636	4382,386	515,586	3519,180	66179,708	38058,444	4448,670
Percentiles	25	2489,38	407,92	224,14	54,01	97,12	4409,88	2758,67	232,95
	50	7354,50	1162,90	657,46	136,51	403,39	11262,08	7434,70	741,21
	75	18146,67	3197,82	1959,98	350,79	1478,89	33392,64	21742,06	2193,92

		X9 Caja y activo a corto	X10 Deuda	X11 Fondos propios	X12 Flujos de caja	X13 Gastos operativos	X14 Dividendos	X15 Capitalización bursátil
n	Válido	928	924	931	930	929	763	893
	Perdidos	183	187	180	181	182	348	218
Media		2936,95	10007,81	11087,84	2572,41	-1335,55	-853,55	30586,59060
Desv. Desviación		8544,823	21076,608	21032,646	5120,323	2597,639	1564,167	78471,64967
Percentiles	25	166,27	1395,77	1208,41	305,47	-1420,15	-808,48	3107,09495
	50	562,52	3497,17	3434,13	859,97	-375,25	-276,27	9379,26330
	75	2383,00	9031,94	10623,00	2468,68	-119,00	-90,33	28243,99120

Tabla 5.16 Valores descriptivos de las variables (2018)

		X1 Ventas	X2 EBITDA	X3 EBIT	X4 Gastos financieros	X5 Beneficio neto	X6 Total Activo	X7 Activos no corrientes	X8 Existencias
n	Válido	1309	1306	1308	1209	1308	1311	1303	1134
	Perdidos	15	18	16	115	16	13	21	190
Media		12169,7934	1981,7947	1211,5177	197,1048	748,9560	19612,2401	13268,5706	1382,6452
Desv. Desviación		28366,14530	4246,59603	2750,54317	404,84485	1986,58168	44816,63167	28951,76422	3175,27312
Percentiles	25	1143,5498	213,6720	95,9395	33,0124	35,7652	2540,4010	1567,1074	91,9906
	50	3465,0105	593,8250	366,0748	74,0470	191,0619	6042,1711	4238,5501	331,3079
	75	10698,1679	1819,7395	1068,2135	194,0894	659,3291	17311,5702	11979,3388	1239,6831

		X9 Caja y activo a corto	X10 Deuda	X11 Fondos propios	X12 Flujos de caja	X13 Gastos operativos	X14 Dividendos	X15 Capitalización bursátil
n	Válido	1297	1300	1308	1307	1300	1005	1227
	Perdidos	27	24	16	17	24	319	97
Media		2041,6645	5758,6009	6894,8950	1602,5134	-1034,1498	-517,2281	18286,1849
Desv. Desviación		9580,07220	13519,00414	14952,59284	3691,67574	2426,59400	1153,56830	39975,22512
Percentiles	25	67,4439	727,2892	827,5483	169,7983	-896,7544	-442,5585	1858,6568
	50	329,9447	1857,6447	2189,8413	497,6325	-289,6825	-156,8297	5807,2503
	75	1399,6291	5094,0083	6206,9051	1386,5852	-87,2581	-48,0782	16645,6456

Tabla 5.17 Valores descriptivos de las variables (2014)

Los valores negativos de algunas variables corresponden a gastos.

Los ratios (R) manejados aparecen, en una primera descripción, a continuación

		R1 Margen EBITDA	R2 Margen EBIT	R3 Margen Beneficio neto	R4 Cobertura Intereses	R5 Ratio de deuda	R6 Deuda financiera neta / EBITDA	R7 Autonomía financiera	R8 Deuda financiera / flujo de caja operacional	R9 Flujo de caja libre
n	Válido	928	928	929	870	924	929	931	923	928
	Perdidos	183	183	182	241	187	182	180	188	183
Media		,1168578022	,0304379764	-,004935689	17,72066995	,5279655659	3,712832509	,3396050815	5,388651998	538,82
Desv. Desviación		2,581601857	2,579622293	2,519388147	49,65923518	,3515534688	21,34237329	,2140459202	32,92026879	2806,181
Percentiles	25	,1011887068	,0505715375	,0260226025	4,734092920	,3345402409	,9425317851	,2416158485	2,251658543	-35,64
	50	,1785219009	,1099796211	,0706579947	8,462151394	,4800844846	2,160020532	,3566122427	3,651246060	148,85
	75	,2858458739	,1902370898	,1315864976	16,28997818	,6373943209	3,938981091	,4673682388	6,194895331	663,14


Tabla 5.18 Valores descriptivos de los ratios (2018)

		R1 Margen EBITDA	R2 Margen EBIT	R3 Margen Beneficio neto	R4 Cobertura Intereses	R5 Ratio de deuda	R6 Deuda financiera neta / EBITDA	R7 Autonomía financiera	R8 Deuda financiera / flujo de caja operacional	R9 Flujo de caja libre
n	Válido	1305	1307	1306	1206	1297	1306	1307	1296	1301
	Perdidos	19	17	18	118	27	18	17	28	23
Media		,2202	,1178	,0806	27,3611	,5061	2,7696	,3594	6,5750	176,3892
Desv. Desviación		,20262	,19807	,83441	139,26020	,36211	25,88967	,18786	37,18274	1616,49081
Percentiles	25	,1025	,0518	,0194	4,2579	,3448	,8418	,2692	2,2276	-100,3008
	50	,1855	,1137	,0598	7,7292	,4763	2,3192	,3677	3,9159	34,7377
	75	,3182	,1951	,1187	15,2154	,5983	4,3083	,4709	6,5735	277,8709

Tabla 5.19 Valores descriptivos de los ratios (2014)

La variabilidad de los ratios financieros es amplia, pues se han considerado empresas de distintos sectores, y que se encuentran en muy distintas situaciones de rentabilidad, liquidez, y equilibrio financiero.

A continuación se describen las variables explicativas (para la muestra de 2018, ya que en la muestra de 2014 los resultados son similares) que se usan para elaborar los ratios en cada sector. Para cada variable, se presenta un diagrama de caja, en el sector que corresponda a la empresa a la que se asocia el dato.


Gráfico 5.1 Distribución de las ventas en cada sector




Gráfico 5.2 Distribución del EBITDA en cada sector




Gráfico 5.3 Distribución del EBIT en cada sector




Gráfico 5.4 Distribución de los gastos financieros en cada sector




Gráfico 5.5 Distribución de los beneficios netos en cada sector




Gráfico 5.6 Distribución de los activos totales en cada sector




Gráfico 5.7 Distribución de los activos no corrientes en cada sector

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS




Gráfico 5.8 Distribución del nivel de inventarios en cada sector




Gráfico 5.9 Distribución de la tesorería y activos a corto plazo por sector




Gráfico 5.10 Distribución de la deuda a corto y largo plazo en cada sector




Gráfico 5.11 Distribución de los fondos propios por sector




Gráfico 5.12 Distribución del cash flow por sectores




Gráfico 5.13 Inversiones en activos productivos por sector




Gráfico 5.14 Distribución de los dividendos pagados por sector




Gráfico 5.15 Distribución de la capitalización bursátil por sector

La tendencia del valor de las variables explicativas con respecto a los *ratings* se aprecia en las tablas siguientes.

S&P's		X1 Ventas	X2 EBITDA	X3 EBIT	X4 Gastos f.	X5 Beneficio	X6 Total Activo	X7 Activo no corr.	X8 Existencias
D a CCC+	Media	8451,14	1292,96	640,31	207,16	220,14	12901,47	9561,24	940,70
	Mediana	2664,40	250,98	30,83	64,57	3,88	3740,36	2653,32	234,11
	Desv.típ.	19810,27	3785,91	2423,76	406,10	1414,42	27087,83	20259,70	1971,23
B- a BB+	Media	8045,48	1155,00	678,01	175,75	388,62	11732,78	7765,17	1042,46
	Mediana	2885,51	441,53	259,54	89,32	119,70	4343,53	3052,22	309,99
	Desv.típ.	16739,18	2572,38	1895,54	311,25	1590,42	24902,19	17218,25	2997,35
BBB- a BBB+	Media	19224,52	3007,40	1752,30	313,19	1219,82	33427,57	22092,92	2166,09
	Mediana	8145,64	1373,58	807,48	135,71	480,43	13399,62	8979,53	772,65
	Desv.típ.	34163,72	5468,52	3607,31	501,29	3390,43	69301,28	39208,12	4368,74
A- a AAA	Media	30395,68	5830,55	3863,88	430,21	2756,96	53243,63	35364,10	3371,25
	Mediana	18072,11	3246,18	2096,02	221,53	1395,40	29643,96	17568,00	1861,86
	Desv.típ.	40375,28	7577,37	5769,06	543,68	4621,42	72466,63	43839,85	5056,77
Total	Media	18159,73	3053,34	1888,77	298,18	1298,03	30969,17	20535,62	2106,63
	Mediana	7182,06	1140,16	681,69	126,61	385,92	10597,94	6800,17	736,65
	Desv.típ.	32478,99	5632,39	4007,36	472,80	3404,66	61497,02	36442,50	4259,89

Tabla 5.20 Tendencia de las variables económico-financieras respecto de los *ratings* (S&P's 2018)

Como se puede observar, las empresas con *ratings* más elevados tienden a tener ventas más altas, así como su EBITDA y EBIT; también mayores gastos financieros; lógicamente, beneficios más elevados, activos y activos no corrientes superiores, y mayor nivel de existencias. Es decir, el tamaño de la empresa parece influir decisivamente en su valoración, tendiendo a valoraciones más altas aquellas corporaciones de mayor entidad.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

S&P's		X9 Caja y activo a corto	X10 Deuda	X11 Fondos propios	X12 Flujos de caja	X13 Gastos operat.	X14 Dividendos	X15 Capital bursátil
D a CCC+	Media	997,72	4437,40	4870,79	1113,88	-855,31	-316,31	8304,57
	Mediana	176,89	1606,68	1123,86	265,93	-192,71	-58,98	1233,88
	Desv.típ.	2262,35	8313,93	10633,82	3423,20	2252,02	740,31	24492,80
B- a BB+	Media	1119,30	4170,31	3621,81	908,51	-509,68	-325,22	8692,15
	Mediana	277,36	1755,20	1171,99	344,16	-128,82	-74,80	3022,15
	Desv.típ.	2886,78	9522,17	8749,89	2072,58	1173,50	863,21	19003,95
BBB- a BBB+	Media	2876,48	10240,56	10990,71	2393,33	-1454,63	-643,22	22670,89
	Mediana	699,00	3635,83	4198,38	1053,03	-451,26	-260,64	11117,03
	Desv.típ.	10210,01	22402,05	20987,71	4317,83	2880,48	1207,66	45570,19
A- a AAA	Media	5738,20	14600,51	19582,22	4764,77	-2235,24	-1579,70	58518,75
	Mediana	2179,27	7178,59	10071,07	2538,58	-1031,07	-669,13	28298,85
	Desv.típ.	12435,98	21211,79	24861,35	6815,75	3272,63	2047,42	101955,92
Total	Media	2958,73	9261,15	10611,26	2458,63	-1333,20	-800,59	26434,94
	Mediana	628,00	3254,03	3463,92	852,06	-381,52	-256,10	9211,12
	Desv.típ.	9344,37	19237,33	19949,59	4746,21	2660,62	1481,94	61600,37

Tabla 5.21 Tendencia de las variables económico-financieras respecto de los ratings (S&P's 2018)

De igual forma, otras variables de los estados contables tienden a crecer con el nivel de *rating*, como los activos a corto plazo, incluyendo la tesorería, la deuda total, especialmente en los niveles de inversión, los flujos de caja, los gastos operativos (el signo menos se puede omitir, pues está asociado a ser gastos), los dividendos (igual consideración sobre el signo), y la capitalización bursátil. Así, también cabe considerar la influencia del tamaño de la firma sobre su calificación.

En el gráfico siguiente, se observa que, al crecer el nivel de *rating*, los valores medios de las variables se van diferenciando, con una tendencia monótona.




Gráfico 5.16 Valores medios de las variables tipificadas medidas (S&P's, 2018)

Los valores medios de las distintas variables muestran una tendencia creciente para todas salvo para los gastos operativos y dividendos, para los que la tendencia es decreciente.

La variable flujos de caja y el total del activo muestran un crecimiento acelerado para las calificaciones más altas. Sin embargo, para la calificación AAA vuelven a disminuir, aunque hay que tener en cuenta que se dispone de pocos datos en esta categoría.

	R1	R2	R3	R4	R5	R6	R7	R8 Deuda financiera / flujo de caja operacional	R9
	Margen EBITDA	Margen EBIT	Margen Beneficio neto	Cobertura intereses	Ratio de deuda	Deuda financiera / EBITDA	Autonomía financiera		Flujo de caja libre
S&P's									

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

D a CCC+	Media	0,0688	-0,070	-0,0959	10,9058	0,6037	1,7237	0,3050	6,9185	56,15
	Mediana	0,1101	0,0265	0,0100	3,7399	0,5361	2,5927	0,3283	5,0971	-6,11
	Desv.típ.	0,4749	0,4638	0,3802	42,2474	0,3092	19,9420	0,2451	68,2851	2249,057
B- a BB+	Media	0,1721	0,0983	0,0459	16,8393	0,6618	4,1123	0,2872	6,2842	174,78
	Mediana	0,1441	0,0849	0,0424	5,7949	0,5571	2,5603	0,3068	4,2894	91,69
	Desv.típ.	0,2112	0,4778	0,4519	155,3865	1,5934	22,7163	0,2372	34,7111	1130,300
BBB- a BBB+	Media	0,1768	0,0938	0,0534	18,8803	0,4869	2,5394	0,3568	4,9702	369,16
	Mediana	0,1760	0,1146	0,0693	9,1563	0,4620	1,9838	0,3618	3,5226	183,27
	Desv.típ.	0,9197	0,9384	1,4106	94,2542	0,3127	13,5049	0,1909	33,1363	2236,214
A- a AAA	Media	0,1507	0,0479	0,0179	34,9991	0,4507	1,9164	0,3780	5,5366	1061,59
	Mediana	0,1983	0,1329	0,0876	13,9891	0,4109	1,4544	0,3818	3,0130	467,50
	Desv.típ.	2,4203	2,5616	2,4649	179,8964	0,4375	7,9369	0,1747	50,0864	4036,502
Total	Media	,1666	,0804	0,0392	21,8397	0,5339	2,8481	0,3395	5,5461	462,10
	Mediana	,1684	,1067	0,0631	8,5188	0,4752	2,0134	0,3515	3,5810	150,99
	Desv.típ.	1,3185	1,4058	1,5322	136,3246	0,9256	16,1671	0,2072	39,3168	2568,504

Tabla 5.21 Tendencia de los ratios financieros respecto de los ratings (S&P's, 2018)

Como los ratios anteriores tienen un rango de variación totalmente diferente, para representar los gráficos anteriores es preferible tipificarlos y así poder comparar su evolución




Gráfico 5.17 Tendencia media de los ratios tipificados respecto de los *ratings* (S&P's, 2018)

El EBIT, el EBITDA, el margen de beneficio neto y el de cobertura de intereses, siguen una tendencia creciente con el nivel de *rating*, mientras que el ratio de deuda sigue una tendencia decreciente. Otros ratios parecen tener menor relación con la calificación.

De nuevo, los ratios financieros tienen el comportamiento esperado. Los valores medianos van creciendo con el *rating*, excepto los relativos a la deuda, que son decrecientes.

Al considerar las variables respecto de las calificaciones otorgadas por la agencia Moody's, los resultados son similares, como se aprecia en las siguientes tablas.

		X1 Ventas	X2 EBITDA	X3 EBIT	X4 Gastos f.	X5 Beneficio	X6 Total Activo	X7 Activo no corr.	X8 Existencias
Moody's									
No prime	Media	9030,41	1247,00	683,49	178,66	374,81	13281,34	8869,89	1159,51
Ca - Ba1	Mediana	2827,36	434,73	252,51	86,58	117,61	4187,24	2931,30	302,51

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	Desv. típ.	19438,93	3093,78	2228,19	304,18	1734,65	29694,13	20605,16	3214,230
Prime 3	Media	17420,17	2600,85	1421,48	249,09	910,01	25997,85	17542,03	2070,04
Baa3	Mediana	7271,09	986,36	635,82	122,51	360,80	9233,51	5461,07	830,19
	Desv. típ.	30499,22	5324,89	3561,18	389,14	3031,27	49451,01	33157,84	3863,49
Prime 2/3	Media	20274,79	3375,85	2060,75	379,95	1554,06	36334,79	26681,47	2107,01
Baa2	Mediana	8314,63	1593,84	878,78	165,00	531,70	15779,96	11060,48	753,51
	Desv. típ.	37406,29	5995,08	3902,75	594,02	4350,57	65600,72	45252,28	4198,15
Prime 2	Media	21523,80	3693,15	2231,47	445,64	1401,10	39935,62	30726,35	2408,75
Baa1	Mediana	9928,69	2236,35	1407,53	211,64	914,62	21581,27	15102,69	1158,66
	Desv. típ.	31868,03	4532,143	3032,35	594,93	2449,68	49241,96	39037,15	3560,20
Prime 1/2	Media	29019,08	5229,15	3427,96	397,60	2395,02	55661,04	31237,20	3862,96
A3 - A2	Mediana	17895,33	3105,00	2018,07	206,22	1393,96	26051,67	16304,53	1730,12
	Desv. típ.	37134,38	6781,57	5040,46	542,74	3754,17	104279,63	44752,22	6964,97
Prime 1	Media	47900,66	9476,35	6333,33	412,63	4904,27	70712,86	46623,08	4407,83
A1 - Aaa	Mediana	35598,25	6197,53	3444,03	297,15	2931,40	52298,00	34626,90	3700,22
	Desv. típ.	56093,80	10675,45	8325,88	462,61	6779,08	73874,71	51378,28	4971,69
Total	Media	19621,00	3321,82	2058,82	315,96	1422,85	33305,31	22443,74	2276,19
	Mediana	8028,98	1233,25	747,57	136,51	427,07	11772,80	7520,36	759,82
	Desv. típ.	34306,21	5964,70	4261,25	490,26	3637,81	63468,41	38633,50	4510,06

Tabla 5.22 Tendencia de las variables económico-financieras respecto de los ratings (Moody's 2018)

		X9 Caja y	X10	X11	X12	X13	X14	X15
Moody's		activo a	Deuda	Fondos	Flujos de	Gastos	Dividendos	Capital
		corto		propios	caja	operat.		bursátil
No prime	Media	1287,28	4546,08	4301,15	1041,68	-649,13	-358,71	9490,02
Ca - Ba1	Mediana	289,70	1740,71	1169,74	355,89	-146,91	-76,84	2946,02
	Desv. típ.	3433,52	11468,59	11333,46	2577,78	1706,89	925,48	20846,92
Prime 3	Media	2426,46	8139,77	8878,14	2236,27	-1275,28	-462,31	21433,86

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Baa3	Mediana	497,88	2750,27	3034,33	846,33	-329,00	-172,00	7947,11
	Desv. típ.	7738,68	18716,21	17430,37	4517,47	2484,88	1052,38	67460,26
Prime 2/3	Media	2944,22	10534,58	13109,15	2721,21	-1719,12	-776,99	25103,01
Baa2	Mediana	649,87	4330,00	4538,06	1216,46	-519,73	-297,60	11988,09
	Desv. típ.	12234,87	19473,05	26711,98	4928,28	3610,95	1422,09	47486,68
Prime 2	Media	2656,24	13412,34	13571,56	2919,56	-1927,84	-885,98	30246,95
Baa1	Mediana	907,82	6151,94	7481,84	1828,90	-830,38	-419,75	18039,21
	Desv. típ.	6691,86	18708,24	15768,83	3501,26	2553,61	1211,39	33997,29
Prime 1/2	Media	5572,43	15921,15	16928,96	3883,46	-1850,58	-1280,30	47062,22
A3-A2	Mediana	2390,49	6760,00	9533,97	2457,54	-937,91	-687,54	28075,70
	Desv. típ.	11617,17	32164,77	20620,58	5267,30	2480,97	1666,73	77258,26
Prime 1	Media	10545,87	17690,48	30626,55	8253,93	-3042,39	-2813,63	109186,03
A1 - Aaa	Mediana	3910,00	10357,91	16056,31	5161,82	-1502,56	-2159,60	69828,50
	Desv. típ.	19900,49	23467,51	34799,36	10037,50	4402,08	2737,60	156714,04
Total	Media	3210,79	9983,15	11576,16	2692,84	-1458,02	-876,95	29329,06
	Mediana	642,38	3358,74	3726,03	974,24	-435,52	-276,75	10131,72
	Desv. típ.	9997,86	20408,40	21160,69	5030,13	2806,55	1562,71	66673,95

Tabla 5.23 Tendencia de las variables económico-financieras respecto de los ratings (Moody's 2018)

La tendencia de los valores medios de las distintas variables tipificadas en relación a los niveles de *rating* agregados se muestra en el gráfico siguiente.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS




Gráfico 5.18 Tendencia de las variables tipificadas respecto de los ratings (Moody's 2018)

Los valores medios de las distintas variables siguen tendencias aproximadamente monótonas respecto del nivel de *rating*; creciente en para todas las variables salvo para los dividendos y para los gastos operativos.

		R1	R2	R3	R4	R5	R6	R7	R8	R9
		Margen EBITDA	Margen EBIT	Margen Beneficio o neto	Cobertura intereses	Ratio de deuda	Deuda financiera / EBITDA	Autonomía financiera	Deuda fin. / flujo de caja operacional	Flujo de caja libre
Moody's No prime	Media	0,1661	0,0878	0,0384	16,8523	0,6738	3,5690	0,2915	4,6264	144,49
	Mediana	0,1421	0,0831	0,0408	5,8316	0,5511	2,5157	0,3138	4,1514	84,64
	Desv. típ.	0,2517	0,5165	0,4864	161,1098	1,6960	13,539	0,2376	35,1680	1255,88
Prime 3	Media	0,0837	-,0011	-,0926	16,2664	0,4647	2,2870	0,3653	4,0607	576,27
	Mediana	0,1509	0,0960	0,0582	8,5069	0,4368	1,8664	0,3745	3,2310	187,17
	Desv. típ.	1,8650	1,899	2,8219	37,9387	0,2449	13,442	0,1608	8,4794	2492,51
Prime 2/3	Media	0,2127	0,1309	0,1037	20,3611	0,4987	2,8365	0,3574	5,0197	290,11
	Mediana	0,1948	0,1207	0,0760	8,7317	0,4731	2,1559	0,3551	3,7276	158,87

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	Desv. típ.	0,1540	0,1679	0,3639	134,0502	0,3656	18,666	0,2264	23,8912	2050,14
Prime 2	Media	0,0991	0,0012	-,0483	14,9764	0,4925	2,7682	0,3564	7,7028	177,59
	Mediana	0,2193	0,1394	0,0866	9,3127	0,4860	2,2254	0,3527	3,7276	230,38
	Desv. típ.	3,2840	3,342	3,3317	21,0113	0,2356	5,6946	0,1549	49,5979	1794,571
Prime 1/2	Media	0,2118	0,1001	0,0868	22,3066	0,4399	1,9558	0,3766	3,9666	839,11
	Mediana	0,1825	0,1198	0,0765	14,7807	0,4072	1,3531	0,3824	2,7568	555,53
	Desv. típ.	0,1381	0,9824	0,4264	32,6393	0,2246	3,0471	0,1756	50,6892	3630,967
Prime 1	Media	0,2210	0,1504	0,1089	75,0264	0,4081	1,5229	0,3981	3,4110	2621,90
	Mediana	0,1975	0,1427	0,0980	20,4306	0,3727	1,2742	0,3934	2,2874	1186,91
	Desv. típ.	0,1476	0,1264	0,1080	345,7534	0,2450	2,5961	0,1744	8,2959	6157,057
Total	Media	0,1658	0,0789	0,0345	22,0511	0,5353	2,7799	0,3426	4,9042	500,00
	Mediana	0,1724	0,1093	0,0654	8,7159	0,4732	2,0026	0,3539	3,5228	159,18
	Desv. típ.	1,4210	1,516	1,6473	143,6143	0,9943	12,5464	0,2069	35,3275	2725,113

Tabla 5.24 Tendencia de los ratios financieros respecto de los ratings (Moody's, 2018)

Gráficamente se representan los valores medios de los ratios anteriores tipificados, en relación a los niveles de *rating* agregados, para la agencia Moody's.




Gráfico 5.19 Tendencia de los ratios medios tipificados respecto de los ratings (Moody's 2018)

Los resultados difieren en parte de los obtenidos para S&P's, pues las tendencias son variables; por ejemplo para la cobertura de intereses y el margen de beneficio neto, en las primeras categorías (más bajas) de *rating*, no parece mostrar tendencia alguna, pero ésta es muy marcada para las calificaciones más altas. Sin embargo, el EBIT y el margen de beneficio neto crecen con la calificación.

Con los datos de 2014, los resultados son similares.




Gráfico 5.20 Tendencia de las variables tipificadas respecto de los ratings (S&P's 2014)

Los dividendos y los gastos operativos siguen una tendencia decreciente con las puntuaciones más elevadas, mientras que las otras variables siguen el comportamiento opuesto.

Sin embargo los distintos ratios tienen un comportamiento que no parece presagiar su carácter predictivo respecto de los niveles de *rating*.




Gráfico 5.21 Tendencia de los ratios medios tipificados respecto de los ratings (S&P's 2014)

El flujo de caja crece para los niveles superiores de calificaciones, aunque muestra una ausencia de relación a partir de los niveles BBB; los ratios de margen de beneficio neto y de deuda son los únicos que tienen una tendencia monótona (en sentidos opuestos) con los niveles de *rating*.

Al analizar las mismas variables para las empresas calificadas por Moody's, las tendencias son similares.

En general, estos gráficos sugieren que en los modelos de predicción de *rating*, son las variables originales, y no los ratios financieros, las que van a mostrar un mayor poder discriminante.

5.4. Modelos basados en técnicas multivariantes

Se inicia el proceso de modelización del nivel de *rating* de las distintas compañías analizadas mediante la utilización de técnicas de análisis estadístico multivariante y usando redes neuronales artificiales.

Las técnicas de Análisis Discriminante son fáciles de aplicar pero las relaciones no lineales entre las variables limitan su uso. Las redes neuronales se empezaron a usar en los ochenta para clasificar bonos.

Al predecir el *rating* es habitual agregar las clases de puntuaciones, y se persigue obtener la predicción de la clase a la que pertenece.

A mayor grado de agregación, mayor es el porcentaje de predicciones correctas. Por ejemplo, Garavaglia (1991) trata de predecir diecisiete clases de puntuaciones, desde la máxima calidad crediticia a la más baja, y su tasa de predicciones correctas alcanza el 23%, y, posteriormente, agrupa los *ratings* en tres clases (grado de inversión, desde AAA hasta BBB, grado especulativo, desde BB hasta C, y la última con la puntuación D), alcanzando un 84% de predicciones correctas. A medida que aumenta la granularidad, es decir, el número de clases a predecir, esta proporción va disminuyendo. Aquí se estiman varios modelos en los que se trata de estimar desde todo el espectro de puntuaciones hasta diversas agregaciones en función de la calidad crediticia.

Con respecto al intervalo de tiempo considerado, en la primera muestra se tienen solo datos del ejercicio 2014, y por lo tanto son los *ratings* de este ejercicio el que se trata de modelizar. Con la segunda muestra, al tener datos de un período de cinco años (2010-14), es posible abordar la predicción dinámica, o al menos, predecir la del último ejercicio teniendo en cuenta la situación en los años anteriores.

En los distintos modelos se usan las variables obtenidas de cada compañía en las bases de datos Bloomberg y los ratios calculados a partir de éstas, empleando una proporción del orden del 70%-80% de los datos disponibles para estimar los modelos, y dejando el 30%-20% restante para validar los resultados de predicción.

Además de las medidas de ajuste habituales y de la proporción de aciertos en la predicción del *rating*, se calcula la proporción de aciertos considerando clases móviles con la categoría inmediatamente anterior y la posterior, pues se considera que las estimaciones de las dos agencias de evaluación empleadas, tienen una variabilidad que alcanza casi el 45% entre las evaluaciones de una y otra, difiriendo éstas en uno o dos escalones en la puntuación.

El primer tipo de clasificación se basa en la utilización de modelos logísticos, para discriminar entre calificaciones de los grados especulativo y de inversión.

En el caso de S&P's, y con los datos del último ejercicio, el modelo logístico seleccionado es el siguiente

	b	Error estándar	Wald	gl	p	Exp(b)
X2 EBITDA	-,001	,000	6,779	1	,009	,999
X4 Gastos financieros	-,008	,002	24,671	1	,000	,992
X5 Beneficio neto	,001	,000	9,836	1	,002	1,001
X10 Deuda	,000	,000	11,202	1	,001	1,000
X14 Dividendos	-,003	,001	7,130	1	,008	,997
X15 Capitalización burs.	,000	,000	27,001	1	,000	1,000
R5 Ratio de deuda	-4,004	,840	22,704	1	,000	,018
Constante	1,093	,439	6,210	1	,013	2,983

Tabla 5.25 Modelo logístico para estimar el grado de inversión-especulación (S&P's, 2018)

cuyos coeficientes son significativos con el test de Wald, y, al aplicarlo a las empresas consideradas, predice el 88.3% del nivel de inversión o especulativo de su calificación, siendo este más alto para las empresas del grupo 'prime'

Observado		Pronosticado		Porcentaje correcto
		S&P's prime-no prime		
		Especulativa	Inversión	
S&P's prime-no prime	Especulativa	93	42	68,9
	Inversión	32	467	93,6
Porcentaje global				88,3

Tabla 5.26 Clasificación-predicción del grado inversión-especulación (S&P's, 2018)

Lógicamente, si se incluyen algunas variables adicionales en el modelo, se mejora su capacidad predictiva.

Para las calificaciones de Moody's se tiene el modelo siguiente en el que las variables explicativas son casi coincidentes con el modelo de S&P's

	b	Error estándar	Wald	gl	p	Exp(b)
X2 EBITDA	-,001	,000	12,312	1	,000	,999
X4 Gastos financieros	-,003	,001	3,546	1	,060	,997
X5 Beneficio neto	,001	,000	8,268	1	,004	1,001
X10 Deuda	,000	,000	14,443	1	,000	1,000
X11 Fondos propios	,000	,000	7,855	1	,005	1,000

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

X13 Gastos operativos	-,001	,000	7,548	1	,006	,999
X14 Dividendos	-,003	,001	8,547	1	,003	,997
X15 Capitalización burs.	,000	,000	18,830	1	,000	1,000
R1 Margen EBITDA	-2,290	,933	6,026	1	,014	,101
R4 Cobertura intereses	,089	,030	8,656	1	,003	1,093
Constante	-,931	,348	7,150	1	,007	,394

Tabla 5.27 Modelo logístico para estimar el grado de inversión-especulación (Moody's, 2018)

alcanzándose un 90.5% de predicciones correctas

Observado		Pronosticado		Porcentaje correcto
		Moodys prime-no prime Especulativa	Inversión	
Moodys prime-no prime	Especulativa	92	28	76,7
	Inversión	25	411	94,3
Porcentaje global				90,5

Tabla 5.28 Clasificación-predicción del grado inversión-especulación (Moody's, 2018)

de nuevo, con mejores resultados para las empresas calificadas en grado de inversión.

ANÁLISIS DISCRIMINANTE

En primer lugar se van a clasificar las puntuaciones de S&P's agregadas en cuatro clases.

Los contrastes de igualdad de medias en estas clases revelan las diferencias significativas para todas las variables y ratios.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	Lambda de Wilks	F	gl1	gl2	p
X1 Ventas	,920	16,997	3	583	,000
X2 EBITDA	,852	33,863	3	583	,000
X3 EBIT	,840	36,993	3	583	,000
X4 Gastos financieros	,945	11,205	3	583	,000
X5 Beneficio neto	,842	36,542	3	583	,000
X6 Total Activo	,890	24,096	3	583	,000
X7 Activos no corrientes	,894	23,062	3	583	,000
X8 Existencias	,948	10,601	3	583	,000
X9 Caja y activo a corto	,927	15,410	3	583	,000
X10 Deuda	,935	13,539	3	583	,000
X11 Fondos propios	,892	23,624	3	583	,000
X12 Flujos de caja	,857	32,325	3	583	,000
X13 Gastos operativos	,920	16,830	3	583	,000
X14 Dividendos	,792	51,169	3	583	,000
X15 Capitalización bursátil	,859	31,968	3	583	,000
R1 Margen EBITDA	,944	11,593	3	583	,000
R2 Margen EBIT	,898	21,987	3	583	,000
R3 Margen Beneficio neto	,866	30,055	3	583	,000
R4 Cobertura intereses	,965	7,039	3	583	,000
R5 Ratio de deuda	,936	13,334	3	583	,000
R6 Deuda fin.neta / EBITDA	,960	8,090	3	583	,000
R7 Autonomía financiera	,951	10,078	3	583	,000
R8 Deuda fin./Flujo caja op.	,984	3,086	3	583	,027
R9 Flujo de caja libre	,970	6,100	3	583	,000

Tabla 5.29 Contrastes de igualdad de medias

Al realizar una clasificación de las puntuaciones de S&P's partiendo de las variables originales, y seleccionando aquellas que muestran mayor poder discriminante, se tienen los siguientes resultados: las funciones discriminantes son

	Función discriminante		
	1	2	3
X1 Ventas	-,340	,741	,097
X5 Beneficio neto	,184	-,729	-,302
X14 Dividendos	,642	,477	,186
R3 Margen Beneficio neto	-,605	,634	,473
R5 Ratio de deuda	,401	-,507	,542
R6 Deuda fin. neta / EBITDA	,078	,235	-,771

Tabla 5.30 Funciones discriminantes canónicas estandarizadas

La tabla de clasificación de los datos originales y de los datos originales mediante la validación cruzada se muestran a continuación

		S&P's	Pertenencia a grupos pronosticada				Total
			D a CCC+	B- a BB+	BBB- a BBB+	A- a AAA	
Original	Frecuencia	D a CCC+	5	6	0	0	11
		B- a BB+	14	82	62	1	159
		BBB- a BBB+	17	65	241	40	363
		A- a AAA	0	8	85	95	188
		Casos sin agrupar	1	13	20	3	37

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

	%	D a CCC+	45,5	54,5	,0	,0	100,0
		B- a BB+	8,8	51,6	39,0	,6	100,0
		BBB- a BBB+	4,7	17,9	66,4	11,0	100,0
		A- a AAA	,0	4,3	45,2	50,5	100,0
		Casos sin agrupar	2,7	35,1	54,1	8,1	100,0
Validación cruzada ^b	Frecuencia	D a CCC+	4	7	0	0	11
		B- a BB+	14	82	62	1	159
		BBB- a BBB+	17	67	236	43	363
		A- a AAA	0	8	85	95	188
	%	D a CCC+	36,4	63,6	,0	,0	100,0
		B- a BB+	8,8	51,6	39,0	,6	100,0
		BBB- a BBB+	4,7	18,5	65,0	11,8	100,0
		A- a AAA	,0	4,3	45,2	50,5	100,0

Tabla 5.31 Clasificación-predicción del rating (S&P's, 2018)

Se tiene que prácticamente el 58% de los casos son clasificados correctamente usando modelos de análisis discriminante, con el subconjunto de las variables *Ventas* (X_1), *Beneficios* (X_5), y *Dividendos* (X_{14}), y con los ratios financieros *Margen de beneficio* (R_3), *Ratio de deuda* (R_5) y *Ratio de deuda sobre el EBITDA* (R_6).

En el caso de Moody's, el proceso de clasificación se realiza de forma similar.

	Función				
	1	2	3	4	5
X4 Gastos financieros	,600	,955	,692	,119	-,096
X8 Existencias	-,291	,269	-,592	,053	,666
X14 Dividendos	,866	,324	,624	-,340	1,069

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

R3 Margen Beneficio neto	-,212	,629	-,083	,230	,282
R5 Ratio de deuda	,258	-,372	,013	,882	,185
X15 Capitalización bursátil	-,356	-,459	,812	-,283	,858

Tabla 5.32 Funciones discriminantes canónicas estandarizadas

Las variables incluidas en el proceso son *Gastos financieros* (X_4), *Existencias* (X_8), *Dividendos* (X_{14}), y *Capitalización bursátil* (X_{15}), además de los ratios *Margen de beneficio* (R_3), y *Deuda* (R_5). La variable *Dividendos* y los dos ratios también se utilizaban en la clasificación de S&P's.

La tabla de clasificación muestra una menor proporción de clasificaciones correctas, aunque se trata de clasificar en seis grupos (en lugar de cuatro):

		Pertenencia a grupos pronosticada							Total
		Moody's	No prime	Prime 3	Prime 2/3	Prime 2	Prime 1/2	Prime 1	
Original	Frecuencia	No prime	55	32	2	13	2	0	104
		Prime 3	11	41	5	7	5	0	69
		Prime 2/3	23	47	7	31	14	0	122
		Prime 2	9	29	11	37	9	0	95
		Prime 1/2	3	24	9	9	32	9	86
		Prime 1	2	7	1	2	8	24	44
		Casos sin agrupar	28	51	5	7	4	1	96
	%	No prime	52,9	30,8	1,9	12,5	1,9	,0	100,0
		Prime 3	15,9	59,4	7,2	10,1	7,2	,0	100,0
		Prime 2/3	18,9	38,5	5,7	25,4	11,5	,0	100,0
		Prime 2	9,5	30,5	11,6	38,9	9,5	,0	100,0

Validación cruzada	Frecuencia	Prime 1/2	3,5	27,9	10,5	10,5	37,2	10,5	100,0
		Prime 1	4,5	15,9	2,3	4,5	18,2	54,5	100,0
		Casos sin agrupar	29,2	53,1	5,2	7,3	4,2	1,0	100,0
	%	No prime	55	32	2	13	2	0	104
		Prime 3	13	38	6	7	5	0	69
		Prime 2/3	23	48	6	31	14	0	122
		Prime 2	9	29	11	37	9	0	95
		Prime 1/2	3	25	9	9	29	11	86
		Prime 1	2	7	1	2	8	24	44
		No prime	52,9	30,8	1,9	12,5	1,9	,0	100,0
		Prime 3	18,8	55,1	8,7	10,1	7,2	,0	100,0
		Prime 2/3	18,9	39,3	4,9	25,4	11,5	,0	100,0
		Prime 2	9,5	30,5	11,6	38,9	9,5	,0	100,0
		Prime 1/2	3,5	29,1	10,5	10,5	33,7	12,8	100,0
		Prime 1	4,5	15,9	2,3	4,5	18,2	54,5	100,0

Tabla 5.33 Clasificación-predicción del *rating* (Moody's, 2018)

En este caso, la proporción de casos (en la validación cruzada) clasificados correctamente es del 36.3%.

Si se trata de predecir las 20 categorías de puntuaciones utilizando un modelo de análisis discriminante, la capacidad predictiva disminuye.

La tabla de clasificación de validación cruzada para la predicción del *rating* de S&P's es la siguiente.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

S&P's 2018	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D	Total
AAA	2									1											3
AA+		1																			1
AA			2		1	1															4
AA-				4	3	1		2		3											13
A+	1				17	3	1		2	3	1	2	1								31
A					1	3	13	2	3	6	5	1	1								35
A-					1	6	4	25	6	13	14		2		4						75
BBB+					1	5	3	12	28	28	11	5	10	7	7		1				118
BBB						2	13	18	36	8	7	20	5	2	3	3	1	5		1	124
BBB-					1	1	2	2	1	13	16	2	16	3	6	2				1	66
BB+								1	6	2	13	8	4	2	1	1	1				39
BB									2	4	8	7	3		1						25
BB-											4	7	10	5				1			27
B+									1				1	4							6
B									2							6	1				9
B-													1				2	1			4
CCC+											1						1				2
CCC																		1			1
CCC-																			0		0
D																				1	0
Total	3	1	2	9	36	28	55	59	109	67	42	73	35	30	13	8	3	8	0	3	584

Tabla 5.34 Clasificación-predicción del rating (S&P's, 2018)

La proporción de *ratings* bien clasificados es del 32.26%, aunque se producen desviaciones sistemáticas en las predicciones de las puntuaciones correspondientes a los niveles BBB, BB y B. Si se considera un intervalo de predicción incluyendo las clases adyacentes, esta proporción asciende a 55.99%, y si el intervalo abarca más/menos dos clases, del 68.84%, cantidades que se verá que son inferiores a las obtenidas con redes neuronales.

La tabla de clasificación-predicción para validar la capacidad predictiva en la clasificación se muestra a continuación.

S&P's 2018	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D	Total
AAA	0	1			1					1											3
AA+	1	0																			1
AA			2		1	1															4
AA-				3	3	2		2		3											13
A+	1				13	5	2		2	3	1	2	1			1					31
A					1	3	12	3	3	6	5		1	1							35
A-					2	8	5	15	7	14	15	1	2	2	4						75
BBB+					1	8	3	12	25	27	11	6	10	7	7		1				118
BBB					1		2	12	17	34	8	8	20	6	3	3	3	1	5		124
BBB-					1	1	3	2	1	13	9	2	21	3	6	2		1		1	66
BB+								1	7	2	7	13	4	2	1	1	1				39
BB									2	4	9	5	4			1					25
BB-											5	7	7	5				3			27
B+									1				1	4							6
B								3	2							2	1		1		9
B-													1			2	0		1		4
CCC+											1						0	1			2
CCC													1					0			1
CCC-																			0		0
D														1						0	1
Total	2	1	2	10	38	32	46	59	108	61	40	81	39	31	12	6	3	11	0	2	584

Tabla 5.35 Clasificación-predicción (dejando 1 fuera) del rating (S&P's, 2018)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

La proporción de clasificaciones correctas cuando se estiman las funciones discriminantes con un datos menos, y se aplican a clasificar este dato son inferiores a las anteriores; en concreto del 23.63% de clasificaciones correctas, del 49.83% cuando se usa un intervalo ampliado a tres clases, y del 64.9% cuando ese intervalo se amplía con las dos clases a cada lado.

En el caso de querer obtener la puntuación otorgada por Moody's, los resultados son similares.

Moody's 2018	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	Total
Aaa	2				1								1								4
Aa1		0																			0
Aa2			2																		2
Aa3				3	1				1												5
A1	1			1	17	2	1	2	4	2	2			1							33
A2				1	4	12	5	4	1	6	1	2	2		1						39
A3					3	4	11	5	8	14	0	1	1								47
Baa1						2	5	40	11	19	2	7	4	4	1						95
Baa2					1	5		13	25	34	4	6	18	10		4	1			1	122
Baa3				1			7	4	5	27	5	4	10	3		2				1	69
Ba1								1		7	5	8	4	3		2					30
Ba2										8	3	8	2	6		1	1				29
Ba3										5		1	8	4						1	19
B1										2		2	1	5							10
B2									1					1	4		1				7
B3												1			1	1				1	4
Caa1													1				2				4
Caa2																		0			0
Caa3																			0		0
Ca																				1	0
Total	3	0	2	6	27	25	29	69	56	124	22	40	52	37	7	11	5	0	0	5	520

Tabla 5.36 Clasificación-predicción del rating (Moody's, 2018)

La proporción de ratings bien clasificados es del 33.27%, aunque se producen desviaciones sistemáticas en las predicciones de las puntuaciones correspondientes a los niveles Baa, Ba y B. Si se considera un intervalo de predicción incluyendo las clases adyacentes, esta proporción asciende a 57.12%, y si el intervalo abarca más/menos dos clases, del 70%, cantidades que se verá que son inferiores a las obtenidas con redes neuronales.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Moody's 2018	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	Total
Aaa	2				1								1								4
Aa1		0																			0
Aa2			2																		2
Aa3				0	4				1												5
A1	1			1	12	7	1	2	4	2	2			1							33
A2				1	4	11	6	4	1	6	1	2	2		1						39
A3					3	6	7	4	10	15	0	1	1								47
Baa1				1	2	2	5	35	11	19	3	8	4	4	1						95
Baa2					7	5	1	14	16	34	4	6	18	10	1	4	1			1	122
Baa3				1			7	4	5	27	5	4	10	3		2				1	69
Ba1							1	1		9	1	9	4	3		2					30
Ba2										10	4	5	2	5		1	2				29
Ba3										5		1	8	4						1	19
B1										2		2	1	5							10
B2									1					1	3	1	1				7
B3												1		1	1	0				1	4
Caa1													1		2	1	0				4
Caa2																		0			0
Caa3																			0		0
Ca													1							0	1
Total	3	0	2	4	33	31	28	64	49	129	20	39	53	37	9	11	4	0	0	4	520

Tabla 5.37 Clasificación-predicción (dejando 1 fuera) del rating (Moody's, 2018)

La proporción de clasificaciones correctas cuando se estiman las funciones discriminantes con un datos menos, y se aplican a clasificar este dato son inferiores a las anteriores; en concreto del 25.77% de clasificaciones correctas, del 52.69% cuando se usa un intervalo ampliado a tres clases, y del 66.73% cuando ese intervalo se amplía con las dos clases a cada lado.

En definitiva, se puede concluir que los modelos logísticos y de análisis discriminante pueden ser útiles para pronosticar si una empresa se puede considerar en los grados de inversión o especulativo, y los modelos de análisis discriminante pueden servir para predecir el nivel de puntuación cuando se agregan éstas en un número reducido de clases, pero no para obtener una estimación fiable del nivel real de *rating*.

5.5. Modelos basados en RNA

Se va a proceder a estimar la calificación crediticia de las empresas de la muestra utilizando redes neuronales artificiales, empezando por las calificaciones agregadas de S&P's y de Moody's en las mismas clases que al plantear los correspondientes análisis

discriminantes, comparando los correspondientes resultados. Las topologías presentadas son las finalmente seleccionadas, tras probar distintas redes alternativas, y prescindiendo de las variables y ratios que muestran menos poder predictivo, con el objetivo de estimar redes lo más simples posibles. La función de activación, en la capa oculta, utilizada ha sido la tangente hiperbólica, que ha proporcionado mejores ajustes que la sigmoïdal.

En el caso de S&P's, se estima una red perceptrón multicapa (MLP) usando como variables de entrada las siguientes: *Ventas* (X_1), *EBITDA* (X_2), *EBIT* (X_3), *Activo* (X_6), *Existencias* (X_8), *Caja e inversiones a corto* (X_9), *Deuda total* (X_{10}), *Fondos propios* (X_{11}), *Flujos de caja* (X_{12}), y los ratios *Cobertura de intereses* (R_4), *Autonomía financiera* (R_7), *Deuda financiera/Flujo de caja* (R_8) y *Flujo de caja libre* (R_9), incluyendo como factor el sector económico. Se incluyen seis neuronas en la capa intermedia. El grafo con la topología de la red es el siguiente

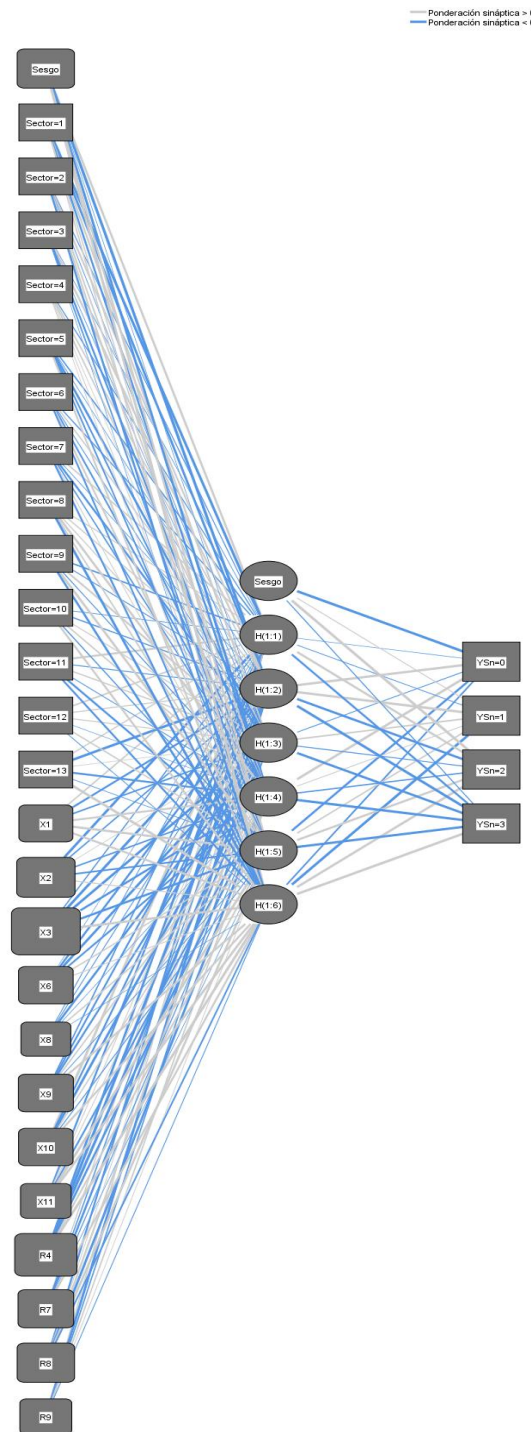


Gráfico 5.22 Topología de la red (S&P's agregada, 2018)

Las funciones de activación son la tangente hiperbólica, en la capa oculta, y la softmax en la de salida. Se han utilizado casi el 80% de los casos en la estimación o entrenamiento de la red, y los restantes para realizar la validación de su capacidad predictiva, resultando unas proporciones de estimaciones correctas del *rating* en el

72.2% y 69.6%, en los correspondientes subconjuntos en los que se ha dividido la muestra, suponiendo una clara mejora respecto del 58% obtenido con el análisis discriminante y respecto a lo referenciado en la literatura. Las correspondientes tablas de clasificación se muestran a continuación

Ejemplo	Observado	Pronosticado				Porcentaje correcto
		D a CCC+	B- a BB+	BBB- a BBB+	A- a AAA	
Entrenamiento	D a CCC+	0	5	3	0	0,0%
	B- a BB+	0	117	36	1	76,0%
	BBB- a BBB+	0	36	215	24	78,2%
	A- a AAA	0	1	52	82	60,7%
	Porcentaje global	0,0%	27,8%	53,5%	18,7%	72,4%
Pruebas	D a CCC+	0	3	0	0	0,0%
	B- a BB+	0	28	8	0	77,8%
	BBB- a BBB+	0	10	56	7	76,7%
	A- a AAA	0	0	20	26	56,5%
	Porcentaje global	0,0%	25,9%	53,2%	20,9%	69,6%

Tabla 5.38 Clasificación-predicción del *rating* (S&P's agregado, 2018)

La curva ROC de especificidad respecto a la sensibilidad para cada una de las clases es la siguiente




Gráfico 5.23 Curvas ROC para cada nivel de *rating* (S&P's agregado, 2018)

Se tiene, pues, una capacidad predictiva homogénea en las distintas categorías. La importancia relativa de las distintas variables predictivas del *rating* se muestra en la tabla siguiente

	Importancia	Importancia normalizada
Sector	,061	34,7%
X1 Ventas	,062	35,2%
X2 EBITDA	,095	54,1%
X3 EBIT	,176	100,0%
X6 Total Activo	,067	38,2%
X8 Existencias	,031	17,7%
X9 Caja y activo a corto	,070	40,1%
X10 Deuda	,066	37,4%

X11 Fondos propios	,037	21,1%
R4 Cobertura intereses	,125	71,2%
R7 Autonomía financiera	,075	42,9%
R8 Deuda financiera / flujo de caja operacional	,089	50,5%
R9 Flujo de caja libre	,046	26,4%

Tabla 5.39 Importancia de las variables explicativas del *rating* (S&P's agregada, 2018)

destacándose las medidas relacionadas con los beneficios y los ratios de duda y autonomía financiera.

En el caso de estimación de las calificaciones crediticias de Moody's, se obtiene una red similar usando como variables de entrada las siguientes: *EBITDA* (X_2), *EBIT* (X_3), *Beneficio neto* (X_5), *Activo* (X_6), *Activos no corrientes* (X_7), *Existencias* (X_8), *Caja e inversiones a corto* (X_9), *Dividendos* (X_{14}), y los ratios *Margen de beneficio neto* (R_3), *Deuda* (R_5), *Autonomía financiera* (R_7), y *Deuda financiera/Flujo de caja* (R_8), incluyendo como factor el sector económico. Se incluyen diez neuronas en la capa intermedia. El grafo con la topología de la red es el siguiente

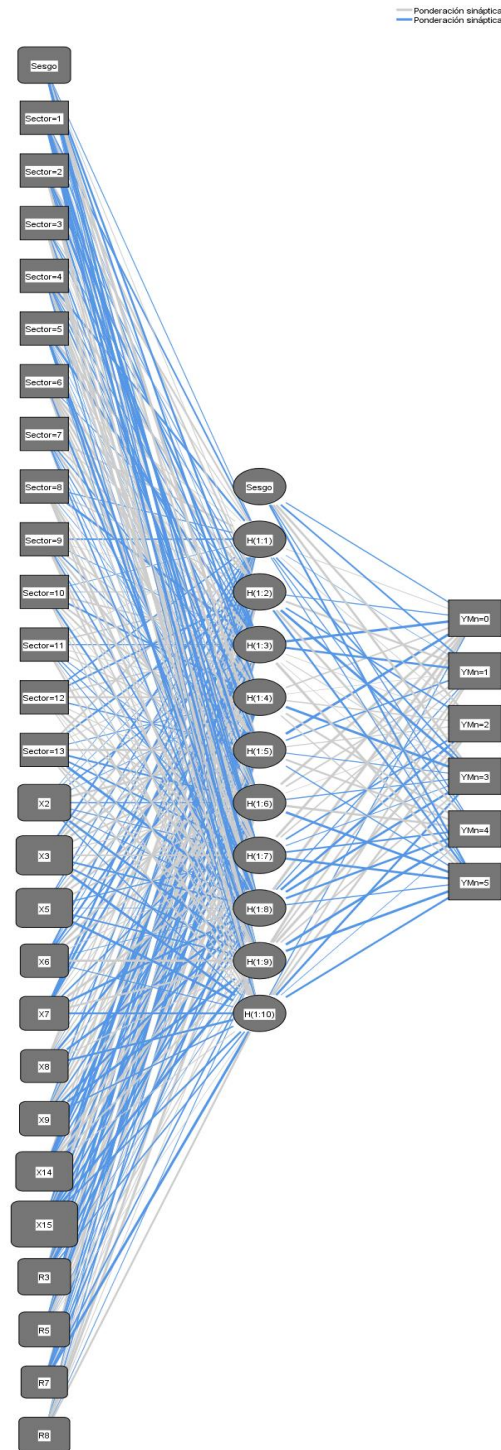


Gráfico 5.24 Topología de la red (Moody's agregada, 2018)

La capacidad predictiva es menor que en el caso de S&P's: un 51.8%, aunque superior al 36.3% obtenido usando técnicas de análisis discriminante.

Ejemplo	Observado	Pronosticado						Porcentaje correcto
		No prime	Prime 3	Prime 2/3	Prime 2	Prime 1/2	Prime 1	
Entrenamiento	No prime	80	1	8	2	1	0	87,0%
	Prime 3	24	6	13	2	5	0	12,0%
	Prime 2/3	24	8	47	13	14	0	44,3%
	Prime 2	6	4	25	24	11	1	33,8%
	Prime 1/2	3	1	9	8	42	3	63,6%
	Prime 1	0	0	3	5	9	19	52,8%
	Porcentaje global	32,5%	4,8%	24,9%	12,8%	19,5%	5,5%	51,8%
Pruebas	No prime	19	0	3	0	0	0	86,4%
	Prime 3	13	2	5	1	2	0	8,7%
	Prime 2/3	3	2	8	4	1	0	44,4%
	Prime 2	2	1	10	5	6	0	20,8%
	Prime 1/2	1	0	2	3	13	1	65,0%
	Prime 1	0	1	1	0	4	3	33,3%
	Porcentaje global	32,8%	5,2%	25,0%	11,2%	22,4%	3,4%	43,1%

Tabla 5.40 Clasificación-predicción del *rating* (Moody's agregado, 2018)

La curva ROC muestra la relación entre la sensibilidad y la especificidad en cada una de las clases de calificación.




Gráfico 5.25 Curvas ROC para cada nivel de *rating* (Moody's agregado, 2018)

La importancia relativa de las variables introducidas aparece en el cuadro siguiente.

	Importancia	Importancia normalizada
Sector	,050	34,2%
X2 EBITDA	,073	50,2%
X3 EBIT	,094	64,1%
X5 Beneficio neto	,094	64,6%
X6 Total Activo	,049	33,9%
X7 Activos no corrientes	,053	36,6%
X8 Existencias	,047	31,9%
X9 Caja y activo a corto	,057	39,1%
X14 Dividendos	,096	65,8%
X15 Capitalización bursátil	,146	100,0%
R3 Margen Beneficio neto	,073	50,1%
R5 Ratio de deuda	,062	42,6%
R7 Autonomía financiera	,041	27,8%
R8 Deuda fin./Flujo caja op.	,064	43,7%

Tabla 5.41 Importancia de las variables explicativas del *rating* (Moody's agregada, 2018)

Finalmente se van a estimar los *ratings* sin ningún tipo de agregación. Es decir, las variables para realizar las predicciones son las calificaciones de S&P's, codificadas con el 1 para la máxima calificación AAA, el 2 para la siguiente AA+, ..., hasta llegar a la 20 para la clase D. La variable Y1e contiene esta calificación.

En el caso de Moody's se asignan estos mismos códigos a las calificaciones Aaa, Aa1,..., hasta la Ca, y se usa la variable Y2e.

En el caso de S&P's se usa la red siguiente con la tangente hiperbólica como función de activación en la capa oculta que incluye nueve neuronas, y Softmax en la de salida.

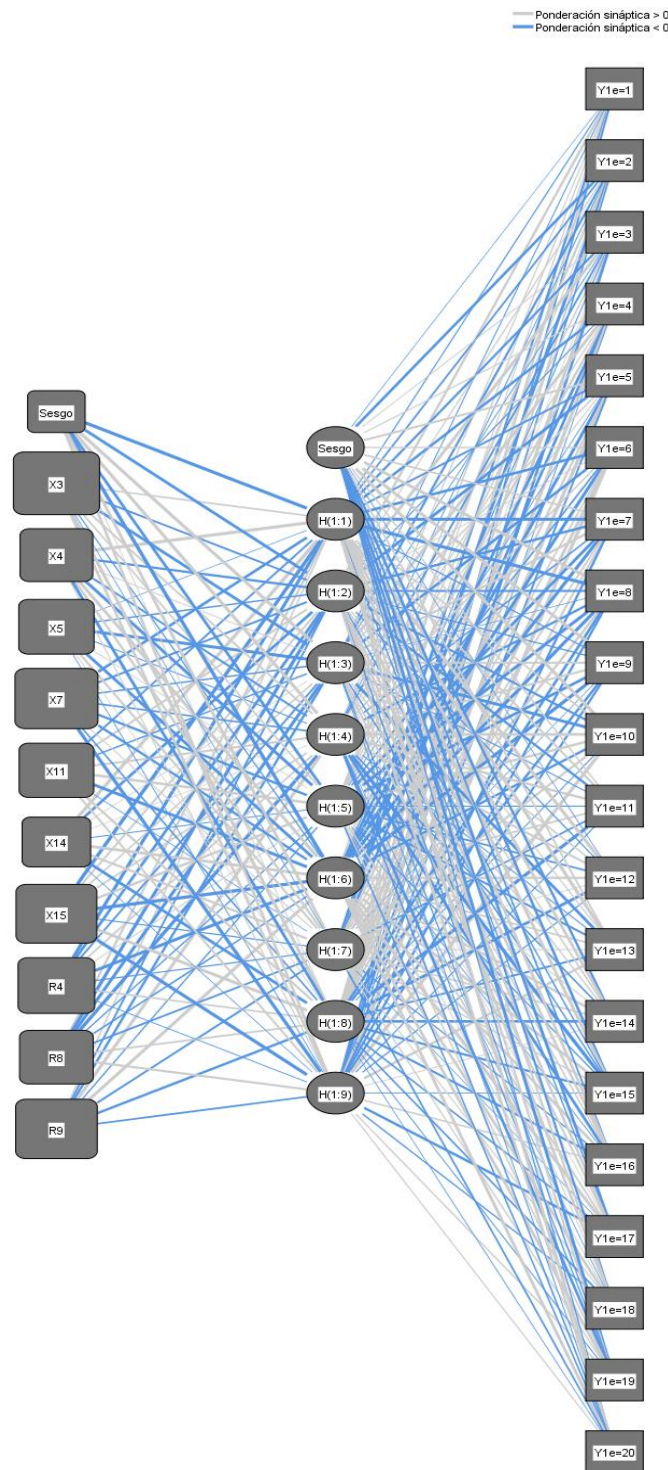


Gráfico 5.26 Topología de la red (S&P's, 2018)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

La proporción de aciertos exactos es del 36.38% y de 31.37% en los dos conjuntos de datos (el de entrenamiento incluye el 75.9% de los casos). Si se consideran los correctos con una aproximación de más menos un nivel de *rating*, estos porcentajes ascienden al 69.85% y al 58.82%; y, si se considera una aproximación de dos niveles, se tiene un 86.28% y 79.08% de correctos. En todos los casos, por encima de otras aproximaciones previas, y con las utilizadas con otras técnicas estadísticas.

S&P 2018	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D	Correctos	Correctos1
AAA	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
AA+	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
AA	0	0	0	4	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4
AA-	0	0	1	2	6	1	3	0	0	0	0	0	0	0	0	0	0	0	0	0	2	7
A+	0	0	0	1	12	1	7	2	2	0	0	0	0	0	0	0	0	0	0	0	12	2
A	0	0	0	0	5	13	3	3	5	0	0	0	0	0	0	0	0	0	0	0	13	8
A-	0	0	0	0	6	4	20	15	13	0	0	0	0	0	0	0	0	0	0	0	20	19
BBB+	0	0	0	0	3	2	8	37	39	1	0	1	0	0	0	0	0	0	0	0	37	47
BBB	0	0	0	0	1	1	4	17	65	3	0	1	4	0	0	0	0	0	0	0	65	20
BBB-	0	0	0	0	0	2	0	7	39	8	0	3	0	0	0	0	0	0	0	0	8	39
BB+	0	0	0	0	0	0	0	1	20	4	0	4	2	0	1	0	0	0	0	0	0	8
BB	0	0	0	0	0	0	0	2	7	6	0	9	1	0	0	0	0	0	0	0	9	1
BB-	0	0	0	0	0	1	0	1	6	0	0	5	5	0	1	0	0	0	0	0	5	5
B+	0	0	0	0	0	0	0	0	1	3	0	2	0	0	0	0	0	0	0	0	0	0
B	0	0	0	0	0	0	0	1	1	0	0	0	4	0	3	0	0	0	0	0	3	0
B-	0	0	0	0	0	0	0	0	0	0	0	2	1	0	1	0	0	0	0	0	0	1
CCC+	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0	0	1	0
CCC	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0
CCC-	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
D	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0
Total	0	0	1	8	34	25	46	86	201	25	0	30	17	0	7	0	1	0	0	0	175	161

Tabla 5.42 Clasificación-predicción para el conjunto de entrenamiento (S&P's, 2018)

S&P 2018	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D	Correctos	Correctos1
AAA	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
AA+	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
AA	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
AA-	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
A+	0	0	0	1	2	0	3	0	0	1	0	0	0	0	0	0	0	0	0	0	2	1
A	0	0	0	0	1	2	0	3	2	0	0	0	0	0	0	0	0	0	0	0	2	1
A-	0	0	0	0	0	2	4	4	9	0	1	0	0	0	0	0	0	0	0	0	4	6
BBB+	0	0	0	0	1	1	4	11	11	0	1	0	0	0	0	0	0	0	0	0	11	15
BBB	0	0	0	1	0	2	2	5	23	0	5	2	0	0	0	0	0	0	0	0	23	5
BBB-	0	0	0	0	0	1	0	2	8	2	0	2	0	0	0	0	0	0	0	0	2	8
BB+	0	0	0	0	0	0	0	0	8	2	0	1	0	0	0	0	1	0	0	0	0	2
BB	0	0	0	0	0	0	0	1	4	1	0	2	0	0	0	0	0	0	0	0	2	0
BB-	0	0	0	0	0	0	0	2	1	1	0	4	2	0	0	0	0	0	0	0	2	4
B+	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0
B	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
B-	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CCC+	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CCC	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
CCC-	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
D	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Total	0	0	0	3	4	8	13	28	67	8	1	14	6	0	0	0	1	0	0	0	48	42

Tabla 5.43 Clasificación-predicción para el conjunto de prueba (S&P's, 2018)

La curva ROC de especificidad-sensibilidad se muestra a continuación y se constata un comportamiento parecido para distintos niveles de *ratings*, aunque en algunos de éstos el número de empresas es pequeño.




Gráfico 5.27 Curvas ROC para cada nivel de *rating* (S&P's, 2018)

y la importancia relativa de las variables explicativas de la clasificación se muestran en el cuadro siguiente; en la escala superior, se muestra la importancia relativa en porcentaje de la variable más influyente




Gráfico 5.28 Importancia de las variables explicativas (S&P's, 2018)

Las variables con mayor importancia en la red son el EBIT, el volumen de activos no corrientes, el flujo de caja, el volumen de capitalización bursátil, el ratio de cobertura de intereses de la deuda, el beneficio neto, el volumen de fondos propios, el ratio de deuda financiera con respecto al flujo de caja, el valor de los gastos financieros y los dividendos pagados.

Otra forma de ver estas curvas es midiendo el área delimitada bajo ellas. Valores más elevados muestran mejor capacidad de predicción.

Se estima a continuación los *ratings* de Moody's sin ningún tipo de agregación. Es decir, las variables para realizar las predicciones son las calificaciones de Moody's, codificadas con el 1 para la máxima calificación Aaa, el 2 para la siguiente Aa1, ..., hasta llegar a la 20 para la clase Ca. La variable Y2e contiene esta calificación.




Gráfico 5.29 Red para estimar los *ratings* de Moody's (2018)

con la tangente hiperbólica como función de activación en la capa oculta que incluye nueve neuronas, y Softmax en la de salida. En este modelo se incluyen las variables

siguientes: *EBIT* (X_3), *Gastos financieros* (X_4), *Beneficio neto* (X_5), *Activos no corrientes* (X_7), *Fondos propios* (X_{11}), *Dividendos* (X_{14}), y *Capitalización bursátil* (X_{15}) y los ratios *Cobertura de intereses* (R_4), *Deuda financiera/Flujo de caja* (R_8) y *Flujo de caja libre* (R_9), incluyendo como factor el sector económico. Se incluyen seis neuronas en la capa intermedia.

En el conjunto de entrenamiento resultan bien clasificados el 42.37%; estos junto con los de la clase adyacente suponen un 73.12% y con un desfase de hasta dos niveles se obtienen 88.84% de bien clasificados. En el conjunto de prueba, el porcentaje de correctos baja sensiblemente, el 32,33% de aciertos en la clase correcta y con las adyacentes la proporción de correctos sube al 70.74%; y en el 85.27% si se considera una desviación posible de dos clases. En las tablas de clasificación de los conjuntos de entrenamiento y de prueba se obtiene el detalle.

Moody's 2018	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2
Aaa	0	0	0	0	2	0	0	0	1	0	0	0	0	0	0	0	0	0
Aa1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
Aa2	0	0	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0
Aa3	0	0	0	0	4	1	0	0	0	0	0	0	0	0	0	0	0	0
A1	0	0	0	0	19	3	3	1	2	0	0	0	0	0	0	0	0	0
A2	0	0	0	0	7	20	3	2	3	0	1	0	0	0	0	0	0	0
A3	0	0	0	0	5	8	9	11	7	1	0	0	0	0	0	0	0	0
Baa1	0	0	0	0	3	2	4	45	19	7	0	0	0	0	0	0	0	0
Baa2	0	0	0	0	1	1	4	15	49	16	3	3	0	0	0	0	0	0
Baa3	0	0	0	0	1	0	1	8	14	25	3	4	0	0	1	0	0	0
Ba1	0	0	0	0	0	0	0	1	7	6	5	4	1	0	1	0	0	0
Ba2	0	0	0	0	0	0	0	1	0	10	7	6	1	0	0	0	0	0
Ba3	0	0	0	0	0	0	0	0	0	11	0	6	2	0	0	0	0	0
B1	0	0	0	0	0	0	0	0	2	0	0	2	3	2	0	0	0	0
B2	0	0	0	0	0	0	0	0	0	1	0	0	1	0	4	0	0	0
B3	0	0	0	0	0	0	0	0	0	0	0	1	2	0	1	0	0	0
Caa1	0	0	0	0	0	0	0	0	0	1	0	1	0	0	1	0	0	0
Caa2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Caa3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Ca	0	0	0	0	0	0	0	0	0	0	0	2	0	0	1	0	0	0
Total	0	0	0	0	45	35	24	84	104	78	19	29	10	2	9	0	0	0

Tabla 5.44 Clasificación-predicción en el conjunto de entrenamiento (Moody's, 2018)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Moody's 2018	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca
Aaa	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Aa1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Aa2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Aa3	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
A1	0	0	0	0	3	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0
A2	0	0	0	0	1	1	0	1	1	0	0	0	0	0	0	0	0	0	0	0
A3	0	0	0	0	0	4	3	0	0	0	0	0	0	0	0	0	0	0	0	0
Baa1	0	0	0	0	0	0	1	7	6	2	0	0	0	0	0	0	0	0	0	0
Baa2	0	0	0	0	3	1	1	8	13	7	3	0	0	0	0	0	0	0	0	0
Baa3	0	0	0	0	0	1	0	0	6	7	1	1	2	0	0	0	0	0	0	0
Ba1	0	0	0	0	0	0	0	1	1	2	2	0	0	0	0	0	0	0	0	0
Ba2	0	0	0	0	0	0	0	0	1	4	1	2	0	0	0	0	0	0	0	0
Ba3	0	0	0	0	0	0	0	0	0	2	0	1	0	0	0	0	0	0	0	0
B1	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0
B2	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0
B3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Caa1	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0
Caa2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Caa3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Ca	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Total	0	0	0	0	8	9	5	21	29	26	7	6	5	1	0	0	0	0	0	0

Tabla 5.45 Clasificación-predicción en el conjunto de prueba (Moody's, 2018)

La curva ROC de especificidad-sensibilidad se muestra a continuación y se constata un comportamiento parecido para distintos niveles de *ratings*, aunque en algunos de éstos el número de empresas es pequeño.




Gráfico 5.30 Curvas ROC para el modelo de Moody's (2018)

De nuevo en este gráfico se aprecia la dificultad de estimar la capacidad predictiva para algunos *ratings* poco frecuentes.

Áreas		
Moody's	Aaa	,960
	Aa1	,998
	Aa2	,991
	Aa3	,956
	A1	,945
	A2	,903
	A3	,864
	Baa1	,854
	Baa2	,790
	Baa3	,779
	Ba1	,839
	Ba2	,890
	Ba3	,928
	B1	,942
	B2	,942
	B3	,977
	Caa1	,906
	Ca	,998

Tabla 5.46 Áreas bajo las curvas ROC

Las variables más influyentes son los fondos propios de las empresas, la cobertura de intereses, los activos no corrientes y la capitalización bursátil.

	Importancia	Importancia normalizada
Sector	,063	52,7%
X3 EBIT	,089	74,5%

X4 Gastos financieros	,098	82,0%
X5 Beneficio neto	,054	45,2%
X11 Fondos propios	,120	100,0%
X14 Dividendos	,082	68,5%
X15 Capitalización bursátil	,101	84,6%
R4 Cobertura intereses	,106	88,4%
R8 Deuda financiera / flujo de caja operacional	,100	83,5%
R9 Flujo de caja libre	,083	69,7%
X7 Activos no corrientes	,105	87,7%

Tabla 5.47 Importancia e importancia relativa de las variables explicativas de la red

Las variables ordenadas por importancia en su capacidad predictiva aparecen en el gráfico siguiente. En la escala superior aparece la importancia normalizada, en proporción de la variable más influyente.




Gráfico 5.31 Importancia de las variables explicativas (Moody's, 2018)

Con la muestra correspondiente a 2014, es más complicado estimar una red debido a la mayor heterogeneidad en los *ratings* y en las variables explicativas. Una alternativa es el utilizar datos de este año y de los cuatro anteriores. Las variables utilizadas, y su representación es ligeramente distinta a la usada en modelos anteriores, por lo que se incluye la lista de variables disponibles en el quinquenio considerado para los modelos siguientes:

X_1 EBIDTA

X_2 EBIT

X_3 Beneficio neto

X_4 Cobertura de intereses

X_5 Ratio de deuda

X_6 Ratio de deuda financiera neta sobre el EBIDTA

X_7 Autonomía financiera

X_8 Ratio de deuda financiera sobre el flujo de caja operacional

X_9 Flujo de caja libre

X_{10} Deuda total

X_{11} Dividendos

X_{12} Capitalización bursátil

El conjunto de entrenamiento en estas redes estimadas con datos del período 2010-14, se ha utilizado el 70% de los casos para estimar los parámetros del modelo, y el 30% para las pruebas y juzgar la capacidad predictiva de cada red.

El grafo de la red estimada se muestra a continuación

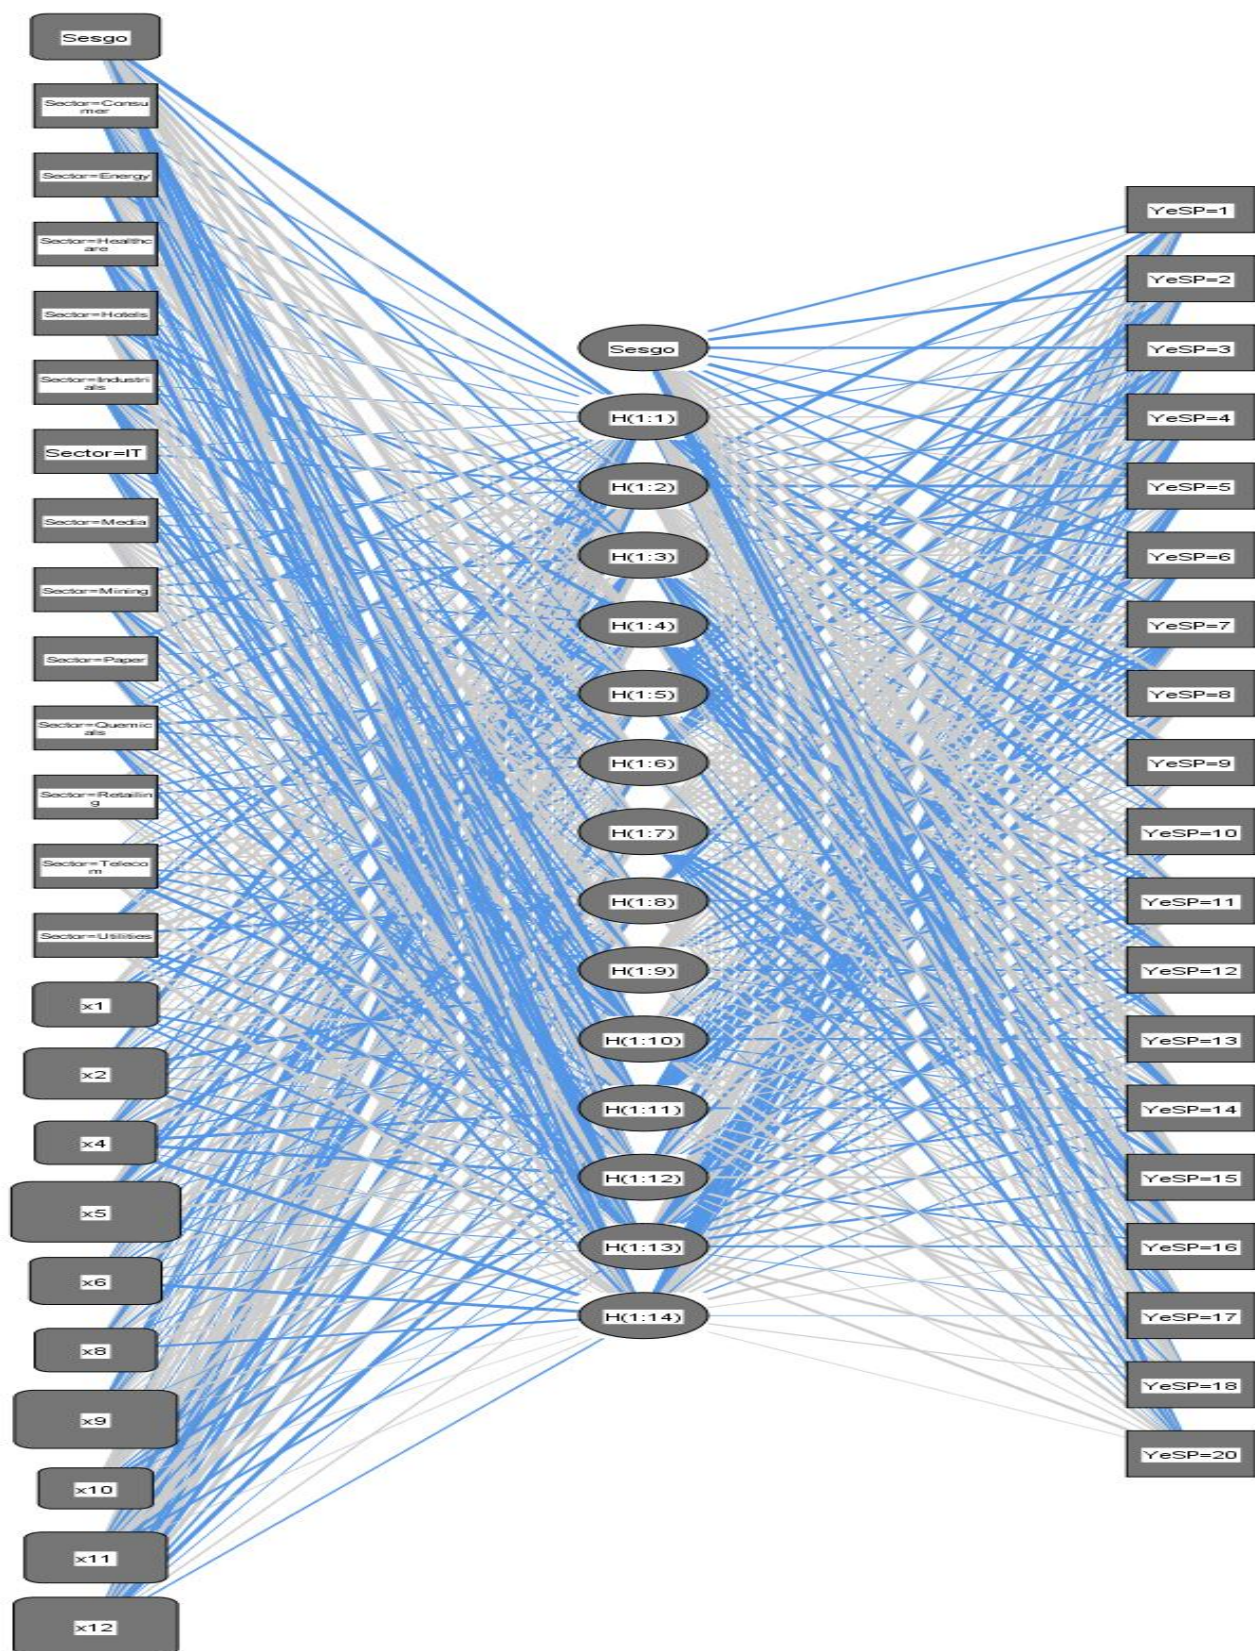


Gráfico 5.32 Red para estimar los ratings de S&P's (2014)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Se ha mantenido el sector económico como factor explicativo, y se consigue una proporción del 36.24% de predicciones correctas en el conjunto de entrenamiento, y un 34.1% en el de prueba. Si se considera un intervalo de predicción incorporando las dos clases adyacentes, estas proporciones suben a un 64.2% y a 63.07%, y con un intervalo que incluya dos clases adyacentes, las proporciones son de un 82.23% y 81.8% en los conjuntos de entrenamiento y de prueba.

Las tablas siguientes muestran estas predicciones para cada uno de los niveles de *rating*, observándose una dispersión mayor en las clases A, BBB, BB y B, es decir en los escalones más bajos del modo inversión y en los más altos del modo especulativo.

S&P 2014	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D
AAA	0		8						2											
AA+	1	2	3																	
AA			26	2	4	1	1													
AA-		2	11	5	15	17	8	3	9	5				1						
A+			2	1	67	23	12	8	19	3		1								
A			1	1	19	52	34	35	46	13	3		1	1		1				
A-		1		2	8	24	154	67	94	10	5	4	2		3					
BBB+				1	3	23	44	153	154	23	11	6	2	4						
BBB		1	3		2	6	52	67	302	35	41	24	3	12	1					
BBB-				2	4	8	49	17	125	71	57	44	11	10	1	1				
BB+					3	4	18	3	57	21	138	47	11	17	7	1				
BB							9	6	70	17	74	78	24	17	7	4				
BB-						5	5	2	14	12	53	17	39	18	11					
B+				1		1	3	3	15	8	42	24	12	76	18	6				
B					1	2	1		5	5	26	1	11	25	54	3				
B-							1	1	3	3	10	2	1	14	25	7				
CCC+										1	1	1	2	1	6		0			
CCC								1		1				1				2		
CCC-																			0	
D					1				1					2						0
Total	1	6	54	15	127	166	391	366	916	228	461	249	120	198	133	23	0	2	0	0

Tabla 5.48 Clasificación-predicción en el conjunto de entrenamiento (S&P's, 2014)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

S&P 2014	AAA	AA+	AA	AA-	A+	A	A-	BBB+	BBB	BBB-	BB+	BB	BB-	B+	B	B-	CCC+	CCC	CCC-	D
AAA	0		2				1		2											
AA+		1						1					1							
AA			11	2	1		1					1		1						
AA-		1	1	3	8	9	4		4	3					1					
A+				2	24	5	2	7	5	2	1									
A				2	7	19	25	14	22	3	1		1							
A-				2	2	12	61	29	30	3	7					1				
BBB+					3	7	18	81	65	6	8	2								
BBB					2	4	23	34	149	17	23	6	3	2	1					
BBB-					3	3	15	7	55	27	22	18	5	5						
BB+					2	2	6	5	31	6	47	18	4	8	3					
BB						1	7		30	14	34	25	8	10	4	1				
BB-						1	5		13	1	33	11	12	12	8	1				
B+							2		4	1	20	16	10	29	10	1				
B						1		3	2		10	2	5	26	15	1				
B-					1				1		3	2		8	3	3				
CCC+							1		3	1	2		1	2	4		0			
CCC											1		1					1		
CCC-																			0	
D														1						0
Total	0	2	14	11	53	65	170	181	416	84	212	101	51	104	50	7	0	1	0	0

Tabla 5.49 Clasificación-predicción en el conjunto de prueba (S&P's, 2014)

La curva ROC de especificidad-sensibilidad se muestra a continuación y se constata el comportamiento del modelo para distintos niveles de *ratings*, aunque en los extremos, el número de empresas es pequeño.




Gráfico 5.33 Curvas ROC para el modelo de S&P's (2014)

Las variables más influyentes son el ratio de deuda (X_5), la capitalización bursátil (X_{12}) y el flujo de caja (X_9); a continuación dos relacionadas con la rentabilidad, el margen del EBIT (X_2). Otras variables tenidas en cuenta son el ratio de la deuda financiera sobre el EBITDA (X_6), y el margen de éste (X_1), el sector, el ratio de deuda financiera sobre el flujo de caja (X_8), la cobertura de intereses (X_4), y la deuda total (X_{10}). La escala superior las muestra ordenadas en relación al ratio de deuda.




Gráfico 5.34 Importancia de las variables explicativas (S&P's, 2014)

El modelo de red propuesto para predecir los *ratings* atribuidos por Moody's en 2014 se estima también con datos del dicho ejercicio y de los cuatro anteriores, usando el 70% de los casos para estimar la red y el resto para evaluar su capacidad de predicción. De nuevo, al disponer de más datos, se ha mantenido el sector como factor explicativo.

El modelo de red propuesto se muestra en el grafo siguiente




Gráfico 5.35 Topología de la red (Moody's, 2014)

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Añadiendo alguna neurona adicional se consigue mejorar ligeramente el ajuste, pero no la capacidad predictiva.

La tabla de predicciones de *ratings* en el conjunto de entrenamiento se muestra a continuación.

Moody's 2014	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca
Aaa	0				8			1	2											
Aa1		0			4															
Aa2			0		13	2														
Aa3				0	27	8		1	2											
A1					71	25	5	17	10	2	2		2	1						
A2					26	50	5	78	33	1	1		1	4						
A3					14	52	47	78	41	8	5		5	7						
Baa1					10	46	20	137	89	21	3		5	1						
Baa2					4	15	6	78	225	36	47		15	5						
Baa3					4	7	10	73	96	57	62		35	5	3					
Ba1					6	12	1	23	86	29	102	2	38	24						
Ba2								19	24	8	90	2	37	27	2					
Ba3					1		4	7	24	13	47	1	67	28	11					
B1					1	3	1	1	7	14	35	1	56	63	4					
B2					1	1	1	3	4	1	10	4	23	21	30		1			
B3						1		1		2	10		6	16	11	0				
Caa1					1					5	1		5	14	3		1			
Caa2					1									1				0		
Caa3										1	1				4				0	
Ca																				0
Total	0	0	0	0	192	222	100	517	643	198	416	10	295	217	68	0	2	0	0	0

Tabla 5.50 Clasificación-predicción en el conjunto de entrenamiento (Moody's, 2014)

Con la red propuesta, la proporción de predicción de *ratings* correcta es del 29.58%, y si se considera un intervalo incorporando las dos clases adyacentes, se alcanza un 59.9%; cuando ese intervalo es de dos clases adyacentes a cada lado, sube a 83.33%.

Igualmente se tiene esta tabla sobre el conjunto de prueba.

V. MODELOS DE PREDICCIÓN DE PUNTUACIONES DE EMPRESAS

Moody's 2014	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca
Aaa	0				2	1		1												
Aa1		0			4						1		1							
Aa2			0		9							1								
Aa3				0	10	1														
A1					30	10	2	13	2	1										
A2					15	32		41	8	2	1		1							
A3					4	17	22	43	19	5	3		1	1						
Baa1					5	20	8	73	38	17	2		4	1						
Baa2					2	15	4	43	67	11	24		4	2						
Baa3						2	7	28	41	14	36		10	5			1			
Ba1					4	7		11	39	14	50	1	14	11						
Ba2						1	1	8	14	3	30	0	15	8						
Ba3						1		4	8	5	21		30	14	1					
B1						1			3	4	20		12	20	1					
B2					1			1			8		9	13	15		1			
B3													1	7	3	0				
Caa1								1	1		1		4	5	2		1			
Caa2																		0		
Caa3																			0	
Ca																				0
Total	0	0	0	0	86	108	44	267	240	76	197	1	107	87	22	0	3	0	0	0

Tabla 5.51 Clasificación-predicción en el conjunto de prueba (Moody's, 2014).

La proporción de predicción de *ratings* correcta es del 28.59%, y si se considera un intervalo incorporando las dos clases adyacentes, se alcanza un 58.89%; cuando ese intervalo es de dos clases adyacentes a cada lado, sube a 83.93%.

Las curvas ROC muestran una capacidad de discriminación bastante similar para los distintos niveles de *rating*.




Gráfico 5.36 Curvas ROC para el modelo de Moody's (2014)

Con respecto a las variables introducidas en la red, el margen de beneficio neto (X_3) es la que aparece con la mayor importancia relativa, seguida de la capitalización bursátil (X_{12}), del ratio de deuda (X_5) y del ratio de deuda financiera sobre el flujo de caja.

En el gráfico siguiente se muestra la lista de variables ordenadas por su importancia (en la escala superior aparece la importancia normalizada).




Gráfico 5.37 Importancia de las variables explicativas (Moody's, 2014)

5.6. Resumen de resultados

Finalmente, se resumen de forma escueta los resultados obtenidos con los distintos métodos para la predicción del *rating* a largo plazo empresarial. En la bibliografía la casi totalidad de las predicciones de las calificaciones se realizan agregando las veinte categorías de *rating* en una pocas clases, y en el caso de usar todas las categorías o un número elevado, los resultados obtenidos son menos precisos que los aquí expuestos. La tasa de aciertos no supera el 23%, cifra está que se supera con los modelos propuestos.

En los modelos en los que se trata de estimar el *rating* sin agregar se proporcionan tres medias: p = proporción de predicciones correctas, p^* = proporción de predicciones correctas o con desviaciones de a lo sumo un nivel de calificación, y p^{**} = proporción de predicciones correctas o con desviaciones de a lo sumo dos niveles de calificación, y se recogen las predicciones realizadas con los conjuntos de datos usados para estimar el

modelo (con $n - 1$ datos en los casos de análisis discriminante, y con una proporción de entre el 70% y el 80% en el conjunto de entrenamiento de las redes), y las predicciones realizadas con datos adicionales (el dato quitado en cada caso en los modelos de análisis discriminante, y los datos del conjunto de prueba de las redes).

a) Modelos estadísticos y de redes con agregación de categorías (datos de 2018):

1. Modelo logit con $c = 2$ categorías: inversión y especulativa

Proporción de predicciones correctas

S&P's $p = 88.3\%$

Moody's $p = 90.5\%$

2. Análisis discriminante:

Proporción de predicciones correctas

S&P's $p = 58.0\%$ $c = 4$ categorías

Moody's $p = 36.3\%$ $c = 6$ categorías

3. Redes Neuronales:

Proporción de predicciones correctas

S&P's $p = 69.69\%$ $c = 4$ categorías

Moody's $p = 51.88\%$ $c = 6$ categorías

b) Modelos estadísticos y de redes sin agregación de categorías (2018): $c = 20$

1. Análisis discriminante

Proporción de predicciones correctas

S&P's Entrenamiento $p = 32.26\%$ $p^* = 55.98\%$ $p^{**} = 68.84\%$

Prueba $p = 23.63\%$ $p^* = 49.83\%$ $p^{**} = 64.90\%$

Moody's Entrenamiento	$p = 33.27\%$	$p^* = 57.12\%$	$p^{**} = 70.00\%$
Prueba	$p = 25.77\%$	$p^* = 52.69\%$	$p^{**} = 66.73\%$

2. Redes neuronales

		Proporción de predicciones correctas		
S&P's	Entrenamiento	$p = 36.38\%$	$p^* = 69.45\%$	$p^{**} = 86.28\%$
	Prueba	$p = 31.37\%$	$p^* = 58.82\%$	$p^{**} = 79.08\%$
Moody's	Entrenamiento	$p = 42.37\%$	$p^* = 73.12\%$	$p^{**} = 88.84\%$
	Prueba	$p = 32.33\%$	$p^* = 70.74\%$	$p^{**} = 85.27\%$

3. Redes neuronales 2010-14

		Proporción de predicciones correctas		
S&P's	Entrenamiento	$p = 36.24\%$	$p^* = 64.20\%$	$p^{**} = 82.23\%$
	Prueba	$p = 34.10\%$	$p^* = 63.07\%$	$p^{**} = 81.80\%$
Moody's	Entrenamiento	$p = 29.58\%$	$p^* = 59.90\%$	$p^{**} = 83.33\%$
	Prueba	$p = 28.59\%$	$p^* = 58.89\%$	$p^{**} = 81.80\%$

En resumen, los modelos de redes proporcionan mejores resultados que los modelos de análisis discriminante para predecir el *rating* exacto, o con desviaciones de uno o dos niveles. No originan sesgos, que si eran claramente visibles en los modelos de análisis discriminante para calificaciones centrales. Lógicamente, a medida que se van agregando las $c = 20$ categorías de *rating* tanto de S&P's como de Moody's, la capacidad predictiva aumenta con todos los modelos.

La posibilidad de predecir los *ratings* sin agregar requiere usar muestras grandes, y en el caso de las redes neuronales todavía más, pues el número de parámetros aumenta de forma rápida al utilizar capas ocultas con un número creciente de neuronas, o si se introducen factores explicativos no numéricos con un número elevado de categorías (como el sector económico al que pertenece la compañía). No es necesario usar más de

una capa oculta en la red, pues no se mejoran los resultados obtenidos con redes en la que solo se tiene una capa oculta.

Las variables con mayor poder explicativo son las asociadas al tamaño de la empresa, los beneficios y su nivel de endeudamiento, así como el valor de capitalización bursátil. Algunos ratios financieros clásicos pueden mejorar el nivel de predicción de la red, como así aparecen en varios de los modelos propuestos. En el caso de las calificaciones de S&P's, suelen aparecer como más influyentes las variables y ratios relacionadas con la dimensión de la empresa, mientras que en el caso de Moody's adquieren mayor importancia las variables relacionadas con los beneficios y con el endeudamiento.

Una cuestión que no queda del todo clara es si es conveniente o no utilizar los datos de los estados contables de varios años atrás para predecir el *rating* a largo plazo de una compañía. En el caso de S&P's los resultados indican que el usar los datos actuales y pasados mejoran la capacidad predictiva del *rating*, mientras que para Moody's no se aprecia esta mejora.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

- 6.1. Problemática en la elaboración de puntuaciones de empresas*
- 6.2. Índices de desplazamiento de las valoraciones de agencias*
- 6.3. Comparación de puntuaciones otorgadas por S&P's y Moody's*
- 6.4. Comparaciones sectoriales*
- 6.5. Resumen de comparaciones*

6.1. Problemática en la elaboración de puntuaciones de empresas

La elaboración de las puntuaciones por parte de las Agencias requiere el uso de distintas metodologías, que varían en las distintas agencias y del tipo de productos. Para distintos sectores de la economía, las agencias utilizan diversos métodos para llegar a obtener la puntuación final otorgada a una empresa en particular.

La inflación de puntuaciones es una realidad en muchos entornos muy diferentes. En el ambiente académico a todos los niveles, existe lo que los anglosajones denominan 'grade inflation', es decir, el procedimiento mediante el cual los discentes obtienen unas calificaciones que no se corresponde con su nivel de aprovechamiento y conocimientos.

Este fenómeno podría originar ramificaciones también en los sistemas de acreditación de empresas, instituciones e incluso de las emisiones de activos financieros.

Todo ello puede que se haya convertido en una tendencia, más o menos acentuada según la región, y se podría una preguntar si las causas que originan estas situaciones tienen raíces comunes.

En el caso que nos ocupa, las puntuaciones atribuidas por las agencias de calificación a empresas pueden variar en función de la agencia emisora de los *ratings*. Por lo tanto, cabe estudiar las diferencias de puntuación atribuidas por agencias distintas a la misma empresa, y, de esta forma evaluar si en algunos casos se tiende a sobrevalorar la capacidad crediticia.

Las puntuaciones atribuidas a una empresa o a una emisión de activos financieros son usadas por los inversores para controlar la calidad y el nivel de riesgo. Esta calidad de la capacidad crediticia ha sido estudiada por diversos autores en la literatura financiera. Así Engelmann *et al*, (2003) y Becker y Milbourn, (2009) realizan una evaluación de la bondad de las predicciones de fallidos en el sector financiero y en su importancia para la supervisión de los mercados. Beatty *et al* (2018) tratan el problema asociado al beneficio que pueden obtener las agencias en función de las puntuaciones generadas; analizan lo que es referido como 'recalibración' de las calificaciones atribuidas por Moody's y por Fitch, que dan lugar a mayores niveles de *rating* sin que exista una causa clara de las mismas. El proceso de 'recalibración' consiste en una rectificación de las probabilidades de fallido incorporando nueva información mediante un proceso de tipo bayesiano. Algunos autores mantienen que es una forma de obtener estimaciones más precisas de las probabilidades de fallido, Kriz y Xiao (2017) estudian los efectos de la 'recalibración' de *ratings* sobre los diferenciales del rendimiento de bonos municipales en los Estados Unidos. Gillette *et al* (2019) tratan el problema en las puntuaciones atribuidas por Moody's. La entrada de la agencia Fitch en el mercado de acreditación es, según varios autores, como Becker y Milbourn (2011) una de las causas del fenómeno de la inflación en las puntuaciones. Su incorporación al mercado incrementó la competencia por atraer clientes para evaluar.

Para evaluar la fiabilidad de las dos agencias, Krämer y Güttler (2005) estudian las predicciones de fallidos realizadas para una muestra de bonos emitidos. Ghosh (2013) tratan un problema similar al que abordamos, es decir, las diferencias entre las dos agencias en las puntuaciones a largo plazo. Si se tienen en cuenta que las definiciones de las puntuaciones en S&P's y en Moody's no son totalmente coincidentes, este hecho puede explicar las diferencias encontradas, al menos parcialmente. Moody's considera 'la verosimilitud de fallido en pagos establecidos contractualmente y la pérdida esperada que sufriría el acreedor si se produce el impago', (Moody's investors Service, 2018), mientras que S&P's considera 'la capacidad e interés del acreedor para cumplir con sus obligaciones financieras a su vencimiento, y su confirmación de colateral y subordinación que pueden afectar al pago en caso de fallido' (Standard & Poor's Ratings Services, 2014). Moody's se refiere a la pérdida esperada, mientras que S&P's cita la probabilidad de fallido. Algunos autores, como Livingston *et al* (2010) comparan

más de mil doscientas emisiones de bonos, sin encontrar diferencias en las puntuaciones de las dos agencias. Sin embargo Bowe y Larik (2014) encuentran que Moody's tiende a ser más conservadora con las puntuaciones asignadas, en la línea que se propone en este trabajo. Bissoondoyal-Bheenick, (2004), detectan estas diferencias, y hacen referencia a la puntuación de México antes de la crisis financiera de 1994, en la que S&P's asignaba un *rating* BB+ mientras que Moody's utilizaba la puntuación Ba inferior. Así, los fallidos en emisiones calificadas por Moody's se concentran más en niveles inferiores que los que se producen en los calificados por S&P's. Pichereau (2016) trata de analizar las causas de las diferencias, y en su conclusión considera que S&P's atribuye mayor importancia a los ratios de apalancamiento, mientras que Moody's pondera más los ingresos totales de una compañía. Bonsall (2014) trata el impacto del sistema de financiación de los *ratings* por parte de los emisores de bonos y activos como una de las causas fundamentales de la inflación en las puntuaciones. Como se ha comentado, la situación previa de financiación por los inversores de la información sobre las empresas y emisiones originaba un proceso de acreditación transparente, aunque originaba menos ingresos para las grandes agencias, comparándolo con los derivados del modelo de pago por parte de los emisores. Los *ratings* deben tener la propiedad estadística de insesgadez, es decir no estar afectados de desviaciones sistemáticas por otras causas distintas a la medición de la salud financiera de una entidad o de una emisión, ya que su misión original consistió en completar la asimetría de información entre los gestores de una compañía y los inversores actuales o potenciales (Sabatino, 2014), los accionistas, los clientes, y, por qué no, los asalariados. Deben cumplir la misión de poder comparar inversiones alternativas en relación al riesgo, y también establecer un común punto de comparación e información sobre el riesgo de crédito. Claro está es que, quizás es mucho pedir para una medida cualitativa (o parcialmente cuantitativa) ordinal; haciendo referencia a la propiedad estadística de suficiencia referida a la no pérdida de información al usar un estadístico muestral respecto a un parámetro poblacional, el *rating* de una empresa es una medida unidimensional y ordinal, mientras que la salud financiera de una compañía es mucho más compleja de medir. Por lo tanto, no hay que olvidar que en este proceso de reducción de dimensión, hay un precio a pagar: no se puede esperar que todas las variables que definen la situación económica de una empresa y de su entorno en su mercado natural, su ubicación geográfica y la situación de otras características internas y externas, no pasen por alto algunos puntos importantes. De hecho, ya se ha comprobado en algunos fallos clamorosos como los

ratings no reflejaban la situación real de Parmalat, Enron, Worldcom, Lehman, y tantas otras 'sorpresas' de los mercados.

En nuestro caso nos centramos en las puntuaciones a largo plazo para empresas, realizadas por un evaluador externo (las dos grandes agencias de acreditación). Para complicar más la situación, no es infrecuente que una misma empresa o institución haya sido evaluada por varias agencias de *rating*. En principio, estas puntuaciones deberían ser coincidentes (a pesar de las diferencias de matiz en los niveles de acreditación entre las tres principales agencias) ya que se está evaluando la salud crediticia y financiera a las mismas compañías. Sin embargo, en la realidad, nos encontramos con diferencias en las evaluaciones atribuidas por diferentes agencias a la misma empresa. Aunque estas diferencias, cuando se dan, no suelen ser elevadas.

Escrig *et al* (2019) tratan sobre la sostenibilidad de los *ratings* en el entorno financiero cambiante en el que nos encontramos. Belas et al (2015) usan los datos financieros directamente para estimar el riesgo al que están sometidas las firmas, referido a pequeñas y medianas empresas. La discriminación entre distintos niveles de puntuaciones ha sido tratada por Yakimova y Kuz (2019), utilizando técnicas de estadística multivariante.

Sobre los posibles conflictos de intereses ya se ha comentado la situación derivada de ser clientes de las agencias las propias empresas evaluadas; originalmente no se daba esta situación, al ser los propios inversores los que financiaban los estudios de riesgo crediticio de las empresas, lo que garantizaba la independencia de los juicios, ya que el interés de estos inversores era precisamente obtener información adicional y objetiva sobre los potenciales destinos de sus fondos. Al aumentar la competencia, en lugar de aumentar la calidad de las evaluaciones, se produce el inicio de la inflación de puntuaciones: al cambiar el modelo de financiación, existe un interés claro en mejorar el *rating* de la compañía evaluada que es a la vez cliente de la agencia evaluadora. Lejos queda la idea inicial de suplir la asimetría de la información entre los gestores de las empresas y los inversores, mediante un evaluador objetivo externo (White, 2018).

Las evaluaciones de activos financieros, como bonos u operaciones activas son más usuales que las de empresas o instituciones. Como se ha comentado, son fundamentales para ayudar en la toma de decisiones de inversión. Además, en muchos casos son requeridas por los reguladores o por los propios fondos de inversión. Las puntuaciones a largo plazo son especialmente útiles en la gestión de carteras. Así pues, cuando una misma compañía es evaluada por varias agencias, sus *ratings* deben ser coincidentes, o al menos, similares, ya que, en principio la información disponible de tipo económico financiera es idéntica. Sin embargo, en la realidad, se observan diferencias, y estas variaciones pueden ser informativas sobre el fenómeno de la inflación de puntuaciones, o, alternativamente, sobre las metodologías, que no son coincidentes, empleadas por las principales agencias.

Las puntuaciones se obtienen a partir de dos fuentes, según manifiestan las propias agencias. La primera es, como no cabría ser de otra forma, la información de los estados contables de cada compañía, es decir, de una información objetiva, si se admite que las cuentas auditadas reflejan fielmente el estado económico-financiero de la empresa. El segundo tipo de información empleada es algo más 'difusa'; alguna agencia la denomina 'datos cualitativos', entre los que se encuentran los informes financieros periódicos, las noticias, los rumores en los mercados, situación del entorno económico y mercantil, y otros; la forma de procesar toda esta información es algo interno de las agencias, sin que éstas lo hagan público. Por ese motivo, no es posible reproducir las puntuaciones (ni comprobar su validez). En el capítulo anterior hemos abordado este problema, modelizando, con relativo éxito, estas puntuaciones crediticias, usando sólo datos objetivos.

Las propias agencias tienen interés en ser fiables en sus evaluaciones, pues es esta fiabilidad reputacional la que les permite sobrevivir en un mundo competitivo. Al ser proveedoras de información, su principal activo es la confianza que inspiran sus evaluaciones. El que los inversores puedan comprobar que, a largo plazo, sus evaluaciones sobre entidades y sobre emisiones de activos sean fiables, les garantiza la continuidad en el mercado. Las condiciones de financiación dependen, en parte, de las

evaluaciones crediticias, por lo que el interés común de las agencias es que sus predicciones se cumplan. En general esto es así: los *ratings* a largo plazo de las agencias de acreditación son fiables; es mucho menos frecuentes que se produzcan fallidos en entidades que gozan de una puntuación elevada que para aquellas que se han evaluado en niveles inferiores. Eso no es óbice para que, de vez en cuando, se haya producido una situación anormal, con fallidos no previstos, y, son precisamente estos fallos los que aparecen en los medios de comunicación y producen noticias que hacen dudar de la bondad de las evaluaciones crediticias.

Los tres grandes, esto es Standard and Poor's, Moody's y Fitch constituyen un oligopolio de hecho, abarcando más de las tres cuartas partes de los ingresos por evaluaciones. Esto podría causar distorsiones en las evaluaciones, pero, esta necesidad de mantener altos niveles de fiabilidad, implica una autorregulación de las grandes compañías que las mantiene en el mercado. Y la competencia entre las tres grandes agencias, tiende a controlar los precios cargados a sus clientes.

Mathis *et al* (2009) consideran el sistema que se considera en equilibrio, en los que los intereses reputacionales de las agencias compensan, al menos en gran parte, los posibles conflictos de interés en las evaluaciones realizadas sobre sus propios clientes. No obstante Xia (2014) señala que el sistema basado en la financiación las agencias por los emisores de activos y por las entidades, producen informes menos adecuados que en el antiguo sistema en el que los inversores pagaban los estudios de *rating*, siendo estos más objetivos y de mayor calidad.

El hecho que los entes reguladores de los mercados financieros impongan condiciones sobre la necesidad de obtener unos ciertos niveles de *rating* en las emisiones de obligaciones y bonos, ha introducido un nuevo factor en el proceso. Las puntuaciones crediticias, que se realizan con un objetivo puramente informativo, y nunca como recomendaciones de inversión (según lo manifiestan repetidamente las agencias, incluso en sus contratos de evaluación con los emisores), adquieren, vía regulación, un carácter

de hecho 'oficial' y obligatorio. ¡Cuán lejos es esta situación de la original, cuando un inversor estaba dispuesto a pagar por una información objetiva!

Además, las barreras de entrada para constituir nuevas agencias se han ido elevando, lo que impide, en la realidad, que se incremente la competencia en el mercado de *ratings*. En los Estados Unidos, la NRSRO, fija las condiciones para ser reconocida como agencia. Los escándalos de Enron, WorldCom y otros, originó la legislación Credit Rating Agency Reform Act, en 2006, con una nueva regulación orientada a poder realizar comparaciones entre los resultados de las agencias registradas. En Europa, a raíz de las propuestas conocidas como Basilea II, los reguladores financieros de cada país establecen que empresas pueden ser reconocidas como agencias que pueden acreditar puntuaciones de emisiones de activos, así como para fijar el capital regulatorio en el sistema bancario y la evaluación de reservas en el sector asegurador. Este reconocimiento se basa en un sistema mínimo de requisitos comunes (Blaurock, 2007); la evolución de los mercados en los últimos treinta años han originado un sistema satisfactorio de equilibrio de tal forma que las agencias consiguen emitir informes fiables, que son aceptados por todas las partes, y que, además, gozan de un nivel suficiente de independencia. Otras regulaciones, como la australiana en 2018, unida a la de los Estados Unidos, pueden establecer la pauta a seguir en el resto de las regiones, en este mercado que está totalmente globalizado. Todo ello en base a unos principios metodológicos adoptados por estos reguladores, que exigen una aproximación analítica, en lugar de una revisión clásica de los estados financieros; en la Unión Europea se exige que esta metodología empleada por las agencias debe ser un proceso continuo, sistemático, riguroso, y, potencialmente sujeto a posible validación (Hemraj, 2015).

Algunos autores, como Kramer y Güttler (2008) comparan los *ratings* de un conjunto de compañías puntuadas en 1998 por S&P's y Moody's analizando sus fallidos hasta 2002, y mantienen que S&P's predice de manera más defectuosas los fallidos que Moody's. Caridad (2020), estudian las diferencias de *ratings* atribuidos por estas dos agencias, llegando a la conclusión que la inflación de puntuaciones se produce más frecuentemente en las evaluaciones de S&P's que en las de Moody's; así lo veremos en los próximos apartados, y referidos a dos períodos de tiempo distintos.

No obstante, es sorprendente, y tranquilizante, que usando distintas metodologías, los resultados de ambas agencias estén tan próximos entre sí.

6.2. Índices de desplazamiento de las valoraciones de agencias

El fenómeno de inflación de *ratings* a largo plazo a empresas, puntuaciones otorgadas por algunas agencias respecto de otras se va a analizar a partir de datos observados de los *ratings* otorgados por las dos principales agencias, S&P's y Moody's, a dos conjuntos de empresas, para las que se dispone de las puntuaciones de ambas. Para ello definen varias medidas, que se han denominado *índices de desplazamiento*, y cuyo objetivo es utilizarlos como herramientas para cuantificar las diferencias de puntuaciones entre dos agencias de calificación, tanto a nivel global, como sectorial.

Además se usan unos contrastes estadísticos no paramétricos, para considerar la significación de las diferencias de *rating* atribuidas por las agencias S&P's y Moody's a dos conjuntos de empresas para las que se dispone de calificación por parte de ambas agencias.

El número de clases consideradas, m , son los 20 niveles de puntuación a largo plazo atribuidos por las agencias de calificación a las empresas (desde AAA o Aaa hasta D o Ca, según se trate de S&P's o de Moody's).

Para representar los valores de los *ratings* se usa la misma codificación de las $m = 20$ categorías consideradas en las calificaciones a largo plazo; es decir, se asignará el valor 1 al máximo valor (AAA o Aaa), el 2 al siguiente (AA+ o Aaa1), y así sucesivamente hasta llegar al valor 20 correspondiente a los *ratings* más bajos (D o Ca).

El asignar valores numéricos a las puntuaciones, que son realmente variables ordinales, se usa para comparar las puntuaciones a largo atribuidas por S&P's y Moody's a un mismo conjunto de n empresas. Para ello se obtiene una tabla de frecuencias $\|n_{ij}\|$, para las $i, j = 1, 2, \dots, m$ categorías de *rating*, siendo n_{ij} la frecuencia de empresas que tienen la i -ésima puntuación en S&P's y la j -ésima en Moody's. Generalmente, estas puntuaciones no deben diferir significativamente, pues representan una medida aproximada de la probabilidad de fallido en las obligaciones financieras a largo plazo de una empresa. De hecho, así ocurre, aunque las diferencias detectadas parecen sugerir que las valoraciones atribuidas por la agencia Moody's son más estrictas (es decir, más bajas) que las de S&P's, apreciándose lo que podría considerarse como una inflación en el nivel de *rating* atribuido por esta última, respecto a las de Moody's. Este fenómeno es el que se analiza en este capítulo, tanto a nivel global de las agencias, como particularizándolo en distintos sectores económicos.

En esta tabla $\|n_{ij}\|$ se aprecia el desplazamiento hacia puntuaciones más estrictas las asignadas por la agencia Moody's. Para ello utilizando las frecuencias de la fila i -ésima (correspondiente a la clasificación i -ésima de S&P's) se proponen dos medidas de desplazamiento de la distribución de las puntuaciones de Moody's hacia valores más elevados que los de S&P's (S_i^+) y del desplazamiento de las puntuaciones de Moody's hacia valores inferiores que los de S&P's (S_i^-). Se introducen unas ponderaciones (w_k) que crecen al alejarse unas puntuaciones de otras; es decir, se valora más una diferencia mayor entre las puntuaciones de las dos agencias que unas diferencias menores. Además, se ponderan de forma simétrica estas desviaciones (una diferencia de un nivel de *rating* entre las dos agencias, se pondera igual en el caso de ser mayor la puntuación de S&P's o si la diferencia es a favor de Moody's). Así es

$$S_1^+ = 0 \quad S_i^+ = \sum_{j=1}^{i-1} w_{i-j} n_{ij} \quad i = 2, 3, \dots, m$$

$$S_i^- = \sum_{j=i+1}^m w_{j-i} n_{ij} \quad i = 1, 2, \dots, m-1 \quad S_m^- = 0$$

Las ponderaciones son tales que $w_1 < w_2 < \dots < w_{m-1}$, y representan el peso que se le asigna a una diferencia de *rating* de 1, 2, ..., $m-1$ unidades. Se consideran igualmente importante las desviaciones positivas o negativas en las diferencias de *rating* de ambas

agencias, y esas ponderaciones correspondientes a una diferencia de k niveles en las puntuaciones de las dos agencias, se consideran independiente de los niveles absolutos de los *ratings*.

Una forma simple de valorar las diferencias entre las puntuaciones entre las dos agencias consideradas es definir

$$w_1 = 1 \quad w_2 = 2 \quad \dots \quad w_{m-1} = m - 1$$

aunque cabe utilizar diferentes sistemas de ponderaciones: Por ejemplo, si se consideran que las diferencias mayores deben valorarse más que proporcionalmente, cabe definir $w_k = k^2$.

Utilizando el sistema de ponderaciones inicial, es decir, $w_k = k$, los *índices de desplazamiento* pueden variar en los intervalos

$$S_i^+ \in [0; n_{i\bullet} w_{i-1}] \quad S_i^- \in [0; n_{i\bullet} w_{m-i}]$$

aunque generalmente tomarán valores pequeños, datos que las diferencias no son elevadas.

El valor 0 corresponde a la no existencia de diferencias de puntuación entre las calificaciones de una agencia respecto de la otra. El valor máximo se produciría cuando hipotéticamente la agencia Moody's puntuara con la máxima diferencia posible en más (o menos) respecto a las empresas que S&P's tiene calificadas en el nivel i -ésimo.

Obviamente, trabajando sobre las columnas de la tabla, se toma como base la calificación j-ésima de Moody's, y se compara las desviaciones en las calificaciones otorgadas por S&P's.

Los valores máximos de los índices de desplazamiento están relacionados entre sí, puesto que su suma, correspondiente a la calificación i-ésima de S&P's es

$$n_{i\bullet}w_{i-1} + n_{i\bullet}w_{m-i} = n_{i\bullet}(n-1)$$

Si se desea reducir el rango de variación de los índices de desplazamiento al intervalo $[0; 1]$, basta dividirlos por su valor máximo obteniéndose los *índices de desplazamiento normalizados*

$$N_i^+ = \frac{S_i^+}{n_{i\bullet}w_{i-1}} \in [0; 1] \quad N_i^- = \frac{S_i^-}{n_{i\bullet}w_{m-i}} \in [0; 1]$$

y toman el valor 0 en el caso que la frecuencia marginal sea nula.

Un valor agregado para medir la inflación de puntuaciones de una agencia con respecto a la otra sería suma de las diferencias entre los índices de desplazamiento normalizados, obteniéndose un índice de inflación de S&P's respecto de Moody's

$$II = \frac{1}{m} \sum_{i=1}^m (N_i^+ - N_i^-) \in [-1; +1]$$

También cabe definir un índice de inflación que no tiene por qué estar acotado, al no considerar los índices normalizados, usando la expresión basada en los índices de desplazamiento divididos por las respectivas frecuencias agregadas a cada lado de la diagonal principal (correspondiente a la coincidencia de *ratings*) de la tabla de frecuencias $||n_{ij}||$

$$H^* = \frac{\sum_{i=2}^m S_i^+}{\sum_{i=2}^m \sum_{j=1}^{m-1} n_{ij}} - \frac{\sum_{i=1}^{m-1} S_i^-}{\sum_{i=1}^{m-1} \sum_{j=i+1}^m n_{ij}}$$

anulándose cualquiera de los sumandos en el caso de ser cero el denominador respectivo. En el caso que el desplazamiento agregado positivo relativo al número de empresas con desplazamiento positivo (es decir que Moody's hubiera asignado puntuaciones más elevadas que S&P's) el primer sumando sería positivo) y si el desplazamiento agregado fuera negativo, relativo al número de empresas con desplazamiento positivo (lo que ocurriría cuando Moody's hubiera asignado puntuaciones más bajas), el segundo sumando compensaría las desviaciones del primero. Así pues, valores positivos mostrarían que Moody's tendería a asignar puntuaciones mayores que S&P's, y si toma valores negativos, que Moody's asignaría puntuaciones inferiores. Globalmente, como ocurre lo último, estos índices tienden a tomar valores negativos, aunque esto no ocurre en todos los sectores económicos, como se verá más adelante.

Para contrastar si existen diferencias entre los *ratings* atribuidos por las dos agencias, se empleará el test de Wilcoxon.

Los datos disponibles para analizar el fenómeno de la inflación de *ratings* serán, por una parte los valores correspondientes a la muestra correspondiente al año 2018, último para el que existen los datos contables completos, formada por $n = 778$ compañías y los datos del año 2014, que los constituyen $n = 905$ empresas, en las que se dispone de los datos de *ratings* de las dos agencias simultáneamente.

El número disponible de empresas con *rating* de Moody's es inferior a las que se manejan con la valoración de S&P's, como se puede apreciar en la tabla siguiente correspondiente a los datos de 2018

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

		S&P's		Moody's	
		Frecuencia	Porcentaje	Frecuencia	Porcentaje
AAA	Aaa	3	,3	3	,3
AA+	Aa1	2	,2	1	,1
AA	Aa2	7	,6	5	,5
AA-	Aa3	21	1,9	10	,9
A+	A1	37	3,3	35	3,2
A	A2	49	4,4	50	4,5
A-	A3	94	8,5	64	5,8
BBB+	Baa1	139	12,5	114	10,3
BBB	Baa2	173	15,6	159	14,3
BBB-	Baa3	103	9,3	100	9,0
BB+	Ba1	68	6,1	53	4,8
BB	Ba2	70	6,3	64	5,8
BB-	Ba3	62	5,6	46	4,1
B+	B1	29	2,6	36	3,2
B	B2	43	3,9	27	2,4
B-	B3	21	1,9	23	2,1
CCC+	Caa1	11	1,0	11	1,0
CCC	Caa2	7	,6	3	,3
CCC-	Caa3	2	,2	1	,1
D	Ca	6	,5	4	,4
Total		947	85,2	809	72,8
Perdidos		164	14,8	302	27,2
Total		1111	100,0	1111	100,0

Tabla 6.1 Ratings disponibles en 2018

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

		S&P's		Moody's	
		Frecuencia	Porcentaje	Frecuencia	Porcentaje
AAA	Aaa	3	,3	3	,3
AA+	Aa1	2	,2	3	,3
AA	Aa2	11	1,0	5	,5
AA-	Aa3	24	2,2	10	,9
A+	A1	39	3,5	41	3,7
A	A2	63	5,7	61	5,5
A-	A3	108	9,7	77	6,9
BBB+	Baa1	129	11,6	103	9,3
BBB	Baa2	173	15,6	133	12,0
BBB-	Baa3	119	10,7	102	9,2
BB+	Ba1	100	9,0	100	9,0
BB	Ba2	100	9,0	69	6,2
BB-	Ba3	71	6,4	72	6,5
B+	B1	72	6,5	54	4,9
B	B2	54	4,9	40	3,6
B-	B3	20	1,8	16	1,4
CCC+	Caa1	10	,9	12	1,1
CCC	Caa2	4	,4	2	,2
CCC-	Caa3	0	,0	2	,2
D	Ca	1	,1	0	,0
Total		1103	99,3	905	81,5
Perdidos		8	,7	206	18,5
Total		1111	100,0	1111	100,0

Tabla 6.2 Ratings disponibles en 2014

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

En ambas muestras, el número de empresas puntuadas por Moody's es inferior a las que se dispone de *rating* otorgado por S&P's.

6.3. Comparación de puntuaciones otorgadas por S&P's y Moody's

Se comparan, a continuación, las puntuaciones atribuidas a las mismas empresas por las dos agencias consideradas, primero para la muestra tomada en 2018 y a continuación para los datos de 2014, calculándose además los correspondientes índices de desplazamiento.

La calificación que proporcionan ambas empresas son similares, y, al cruzar ambas, se muestran las que son coincidentes en la diagonal de la tabla siguiente (resaltadas en negrita, en color rojo los casos en los que S&P's otorga una puntuación más baja que Moody's, y en verde aquellas en que la puntuación de Moody's es más baja que la de S&P's)

		Moody's																			Total
		Aaa	Aa 1	Aa 2	Aa 3	A 1	A 2	A 3	Baa 1	Baa 2	Baa 3	Ba 1	Ba 2	Ba 3	B 1	B 2	B 3	Caa 1	Caa 2	Caa 3	
S&P's	AAA	3																			3
	AA+		1	1																	2
	AA			3	2	2															7
	AA-			1	6	8	2	1													18
	A+				2	20	9	3	1												35
	A					3	30	10	3												46
	A-					2	9	34	27	6											78
	BBB+							14	59	42	2	1									

BBB							1	22	86	32	3															144
BBB-								1	18	51	11	2														83
BB+										5	26	23	1													55
BB										1	9	23	18	5												56
BB-											1	10	18	12	2											43
B+												5	5	11	4	1										26
B													2	5	15	8										30
B-															3	11	2									16
CCC+															1	2	5									8
CCC																	2	1					1			4
CCC-																		2	0						2	
D																	1						3			4
Total	3	1	5	10	35	50	63	113	152	91	51	63	44	33	25	22	10	3	0			4				778

En la mayoría de los escalones de la clasificación, se observa que Moody's tiende a una puntuación ligeramente inferior a la de S&P's. Al haber codificado con los mismos valores ambas valoraciones, se obtiene la diferencia entre éstas, para cada empresa, y, al tabular los resultados se observa la asimetría que muestra la tendencia hacia adjudicar menores puntuaciones por parte de Moody's.

S&P's/Moody's	S+	S-
AAA	0	0
AA+	0	1

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

AA	0	6
AA-	1	15
A+	2	18
A	3	16
A-	13	39
BBB+	14	49
BBB	24	38
BBB-	20	15
BB+	5	25
BB	11	28
BB-	12	16
B+	15	6
B	9	8
B-	3	2
CCC+	4	0
CCC	2	2
CCC-	2	0
D	3	0
Total	143	284

Tabla 6.4 Índices de desplazamiento de Moody's con respecto a cada nivel de S&P's (2018)

Esta tendencia es clara en todas las categorías *prime*, es decir correspondientes a niveles de inversión, e incluso en los primeros niveles de las categorías especulativas. Sin embargo, el fenómeno contrario ocurre en los niveles *no prime* más bajos de *ratings*. Los índices normalizados para cada categoría muestran tendencias idénticas.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Globalmente, se observa una tendencia de asignar *ratings* superiores por parte de S&P's respecto de Moody's. Los índices de inflación normalizado o no son $II = -0.0258$ y $II^* = -0.0332$; los valores negativos indican la tendencia de Moody's a asignar niveles de *rating* inferiores a S&P's, es decir, una tendencia de esta última agencia de asignar puntuaciones más altas o 'infladas' (menor probabilidad de fallido a largo plazo) que las asignadas por Moody's.

Finalmente, para realizar una comparación a nivel global entre los *ratings* asignados por ambas agencias, cabe realizar varios contrastes no paramétricos sobre la identidad entre las distribuciones de estas puntuaciones (ordinales) en las empresas que han sido evaluadas por las dos agencias. El test de Wilcoxon presenta los siguientes resultados.

		n	Rango promedio	Suma de rangos
Moody's - S&P's	Rangos negativos	127 ^a	182,93	23332,50
	Rangos positivos	245 ^b	189,35	46145,50
	Empates	406 ^c		
	Total	778		$p = 1.694 \times 10^{-9}$

a. Moody's < S&P's b. Moody's > S&P's c. Moody's = S&P's

Tabla 6.5 Test de Wilcoxon para comparar las distribuciones de *ratings* de S&P's y Moody's

A pesar de haber encontrado 406 empresas (de las 778 disponibles) con el mismo nivel de *rating* en las dos agencias, se acepta con claridad la tendencia de S&P's en atribuir *ratings* más elevados que Moody's a las mismas empresas. Se ha incluido en la tabla la probabilidad límite (bilateral) que es bajísima, apoyando la decisión de aceptar que las diferencias son significativas; en el caso de plantear la decisión unilateral, es decir, en la que la hipótesis alternativa refleje el que la distribución de los *ratings* otorgados por Moody's tienda a desplazarse a la izquierda de la distribución de los de S&P's, la probabilidad límite sería todavía más pequeña, esto es, a aceptar esta hipótesis alternativa. De igual forma, en el test de signos, se obtendría una probabilidad límite del

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

mismo orden de magnitud, confirmándose la aceptación de la correspondiente hipótesis alternativa.

En los diagramas de caja siguientes, los valores mayores corresponden a peores calificaciones crediticias (el valor 1 se asociaba al nivel AAA o Aaa, y el valor 20 a la calificación D o Ca).

En el 52.2% de los casos, el nivel de clasificación coincide en ambas consultoras. S&P's proporciona una calificación un nivel superior a Moody's en el 14.4% de las veces, y muy rara vez dos o tres escalones superiores. Sin embargo, Moody's proporciona una calificación inferior en un escalón en el 26.9% de los casos, dos niveles inferiores en el 4.2%, y rara vez tres o más niveles inferiores. La proporción de rangos positivos es casi el doble de los negativos, avalando así con claridad las diferencias entre las dos distribuciones que se muestran en los diagramas de caja siguientes.




Gráfico 6.1 Distribución de los ratings atribuidos por S&P's y Moody's (2018)

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Los dígitos empleados en la codificación de los *ratings* son tales que las valoraciones mejores corresponden a los códigos más bajos. También cabe apreciar que la distribución de S&P's está más concentrada alrededor de valores centrales que en el caso de Moody's, lo que parece indicar que la primera asigna puntuaciones menos extremas; es decir, que discrimina menos en la valoración de las empresas que Moody's.

Gráficamente cabe apreciar las diferencias antes comentadas mediante un diagrama de barras, en el cual el eje de abscisas corresponde a las diferencias de los *ratings* atribuidos por S&P's y por Moody's. Los valores negativos corresponden a los niveles de diferencias a favor de la primera, es decir, en los que se observa la inflación de puntuaciones.




Gráfico 6.2 Diferencias entre el nivel de clasificación de S&P's y el de Moody's (2018)

Estas diferencias se encuentran tabuladas a continuación.

Diferencias	Frecuencia	Porcentaje
-3	3	0,3
-2	33	3,0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

-1	209	18,8
0	406	36,5
1	112	10,1
2	14	1,3
3	1	0,1
Total	778	70,0
Perdidos	333	30,0
Total	1111	100,0

Tabla 6.6 Diferencias entre el nivel de clasificación de S&P's y el de Moody's (2018)

En definitiva, los resultados obtenidos con las distintas medidas y representaciones de la información apuntan todos en el mismo sentido: Moody's realiza una asignaciones de *ratings* que se podrían calificar de más rigurosas que S&P's, asignando puntuaciones más extremas en los casos necesarios, aunque con una tendencia a asignar *ratings* algo más bajos que S&P's. Además, S&P's tiende a asignar valores más centrales (es decir, menos comprometidos en su apreciación) que Moody's. Los índices de desplazamiento en cada nivel muestran esta doble situación, confirmando la tendencia a inflación de *ratings* en S&P's respecto de Moody's, y la tendencia de la primera en el conservadurismo en la asignación en niveles inferiores.

La probabilidad límite en el test de hipótesis alternativa unilateral, en la que se considera la distribución de calificaciones de S&P's desplazada a la derecha de la distribución de Moody's, es $p < 0.0000001$. En consecuencia, parece claro que S&P's tiende a 'inflar' las calificaciones crediticias respecto de Moody's. Hay que tener en cuenta que son las propias empresas las que suelen solicitar a las agencias calificadoras que les calculen el *rating* correspondiente, y les pagan los honorarios a éstas por tal labor. Por lo tanto, cabe la posibilidad que se produzca un conflicto de intereses en el que el resultado podría ser atribuir *ratings* que denotan más solvencia que la real a una compañía, que a la vez es cliente. De hecho Moody's tiende a atribuir calificaciones

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

ligeramente de menor solvencia (frecuencias en verde), y también, tiene menos empresas que le solicitan que les valore en su *rating*.

Con los datos de la segunda muestra, correspondiente al año 2014, también la calificación que proporcionan ambas empresas son similares.

	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	4																				4
AA+		1			1																2
AA		3	4		3	2															12
AA-		1	1	15	8	1		1													27
A+				7	15	13	4														39
A					11	35	12	8													66
A-					4	12	50	26	7												99
BBB+						3	16	59	32	5	1										116
BBB							4	29	84	32	3										152
S&P's BBB-								4	20	69	20	2									115
BB+										10	55	27	5								97
BB									1	2	15	43	34	5							100
BB-												10	33	18	4	1					66
B+													1	16	40	17	2				76
B														2	11	24	16	1	1		55
B-														1	2	2	11	14	1		31
CCC+																	1	6		1	9
CCC																		1	2	1	4
CCC-																1		2	1	1	5

1	2
2	1077

1	2
2	1077

1	2
2	1077

1	2
2	1077

1	2
2	1077

1	2
2	1077

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

B+	15	15
B	12	5
B-	4	5
CCC+	1	0
CCC	0	2
CCC-	0	0
D	0	0
Total	143	284

Tabla 6.8 Índices de desplazamiento de Moody's con respecto a cada nivel de S&P's 2014

Esta tendencia es clara en todas las categorías *prime*, es decir correspondientes a niveles de inversión, e incluso en las categorías especulativas, a diferencia de lo observado en 2018. Los índices normalizados para cada categoría muestran tendencias idénticas.

Globalmente, se observa una tendencia de asignar *ratings* superiores por parte de S&P's respecto de Moody's. Los índices de inflación normalizado o no son $II = -0.0294$ y $II^* = -0.1224$, valores claramente inferiores a los observados en 2018; los valores negativos indican la tendencia de Moody's a asignar niveles de *rating* superiores a S&P's, es decir, una tendencia de esta última agencia de asignar puntuaciones más altas (menor probabilidad de fallido a largo plazo) que las asignadas por Moody's.

Finalmente, para realizar una comparación a nivel global entre los *ratings* asignados por ambas agencias, cabe realizar varios contrastes no paramétricos sobre la identidad entre las distribuciones de estas puntuaciones (ordinales) en las empresas que han sido evaluadas por las dos agencias. El test de Wilcoxon presenta los siguientes resultados.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

		<i>n</i>	Rango promedio	Suma de rangos
Moody's - S&P's	Rangos negativos	128 ^a	185,09	23768,00
	Rangos positivos	275 ^b	209,59	57638,00
	Empates	502 ^c		
	Total	905		$p = 1.4 \times 10^{-15}$

a. Moody's < S&P's b. Moody's > S&P's c. Moody's = S&P's

Tabla 6.9 Test de Wilcoxon: comparación de las distribuciones de *ratings* de S&P's y Moody's

A pesar de haber encontrado 502 empresas (de las 905 disponibles) con el mismo nivel de *rating* en las dos agencias, se acepta con claridad la tendencia de S&P's en atribuir *ratings* más elevados que Moody's a las mismas empresas. Se ha incluido en la tabla la probabilidad límite (unilateral, pues se ha observado la tendencia de S&P's de inflar las puntuaciones respecto de Moody's, y es esta hipótesis la que se estudia) que es bajísima, apoyando la decisión de aceptar que las diferencias son significativas; en el caso de plantear la decisión bilateral, es decir, en la que la hipótesis alternativa refleje el que la distribución de los *ratings* otorgados por Moody's difiera de la de S&P's, la probabilidad límite sería aproximadamente el doble de la presentada. De igual forma, en el test de signos, se obtendría una probabilidad límite del mismo orden de magnitud, confirmándose la aceptación de la correspondiente hipótesis alternativa.

En los diagramas de caja siguientes, los valores mayores corresponden a peores calificaciones crediticias (el valor 1 se asociaba al nivel AAA o Aaa, y el valor 20 a la calificación D o Ca).

En el 52.2% de los casos, el nivel de clasificación coincide en ambas consultoras. S&P's proporciona una calificación un nivel superior a Moody's en el 14.4% de las veces, y muy rara vez dos o tres escalones superiores. Sin embargo, Moody's proporciona una calificación inferior en un escalón en el 26.9% de los casos, dos niveles inferiores en el 4.2%, y rara vez tres o más niveles inferiores. La proporción de rangos positivos es casi

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

el doble de los negativos, avalando así con claridad las diferencias entre las dos distribuciones que se muestran en los diagramas de caja siguientes.




Gráfico 6.3 Distribución de los *ratings* atribuidos por S&P's y Moody's (2014)

Los dígitos empleados en la codificación de los *ratings* son tales que las valoraciones mejores corresponden a los códigos más bajos.

Gráficamente cabe apreciar las diferencias antes comentadas mediante un diagrama de barras, en el cual el eje de abscisas corresponde a las diferencias de los *ratings* atribuidos por S&P's y por Moody's. Los valores negativos corresponden a los niveles de diferencias a favor de la primera, es decir, en los que se observa la inflación de puntuaciones. Las diferencias son superiores en 2014 a las que se detectan en el año 2018.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS




Gráfico 6.4 Diferencias entre el nivel de clasificación de S&P's y el de Moody's (2014)

Diferencias	Frecuencia	Porcentaje
-7	1	,1
-4	1	,1
-3	5	,5
-2	41	3,7
-1	227	20,4
0	502	45,2
1	121	10,9
2	5	,5
3	2	,2
Total	905	81,5
Perdidos	206	18,5
Total	1111	100,0

Tabla 6.10 Diferencias entre el nivel de clasificación de S&P's y el de Moody's (2014)

En definitiva, los resultados obtenidos con las distintas medidas y representaciones de la información apuntan todos en el mismo sentido: Moody's realiza una asignaciones de *ratings* que se podrían calificar de más rigurosas que S&P's, siendo las diferencias detectadas en el año 2014 superiores a las de 2018. Los índices de desplazamiento en cada nivel muestran esta situación a lo largo de este período de tiempo, confirmando la tendencia a inflación de *ratings* en S&P's respecto de Moody's, y la tendencia de la primera en el conservadurismo en la asignación en niveles inferiores.

Además, entre las agencias de acreditación, Moody's aparece como más transparente en el proceso de evaluar a las empresas. Utiliza el modelo KMW² (Baltaev y Chavdarov, 2014), para estimar la probabilidad de fallido (*Probability of Default*, PD) o, en la terminología de Moody's terminology, la frecuencia esperada de fallido (*Expected Default Frequency*, EDF), que no es sino la probabilidad de fallido con un horizonte temporal de un año. En este modelo se incorporan tres tipos de información: el valor de los activos, el nivel de riesgo al que están expuestos, y la protección de estos mediante instrumentos de apalancamiento. De esta forma se estima la volatilidad de los activos, y lo que denominan 'distancia a fallido' que es la base para evaluar la PD.

Al analizar datos similares desde el año 2004, se observa el comportamiento referido en ambas agencias, detectándose una inflación parcial de *ratings* en S&P's respecto de Moody's, con una tendencia a converger a largo plazo en sus asignaciones de *ratings*.

² KMV es la empresa de análisis cuantitativo de la gestión del riesgo, creada en 1989 por Kealhofer, McQuown y Vasicek, empresa en la que se desarrolló una versión modificada del modelo de Merton para valorar activos financieros; fue adquirida por Moody's en 2002, renombrándola Moody's KMV

6.4. Comparaciones sectoriales

Analizando la distribución por sectores económicos de las empresas contenidas en las dos muestras utilizadas, correspondientes a los años 2014 y 2018, se tiene la siguiente distribución

	2014		2018	
	Frecuencia	Porcentaje	Frecuencia	Porcentaje
Consumo	94	7,1	105	9,5
Energía	189	14,3	91	8,2
Sanidad	71	5,4	73	6,6
Hoteles'	20	1,5	21	1,9
Industrial	251	19,0	256	23,0
Informática	116	8,8	126	11,3
Medios	52	3,9	66	5,9
Minería	37	2,8	52	4,7
Papeleras	24	1,8	28	2,5
Química	44	3,3	46	4,1
Comercial	68	5,1	71	6,4
Telecomunicación	86	6,5	48	4,3
Utilidades	272	20,5	128	11,5
Total	1324	100,0	1111	100,00

Tabla 6.11 Estructura de las muestras correspondientes a los años 2014 y 2018

Al disponer de información de *ratings* atribuidos por S&P's y por Moody's a un gran número de empresas de los distintos sectores, cabe también realizar un análisis de las evaluaciones en cada uno de ellos para estudiar las diferencias correspondientes.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Consumo	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				4	1																5
A+					6																6
A					1	4	1	1													7
A-					1	2	4	2	1												10
BBB+							1	5	2												8
BBB							1	4	8	2											15
BBB-									2	7											9
BB+										2	1	2									5
BB											1	0	2								3
BB-													5								5
B+														2		1					3
B														1	0						1
B-																1					1
CCC+																	0				0
CCC																		0			0
CCC-																			0		0
D																				0	0
Total	0	0	0	4	9	6	7	12	13	11	2	2	7	3	0	2	0	0	0	0	78

Tabla 6.12 Rating de S&P's y Moody's (2018) Sector 'Consumo'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

En este sector las dos agencias proporcionan puntuaciones muy similares, sin que se produzcan valores extremos.

Consumo	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			1																		1
AA-				2	1																3
A+					2																2
A					2	6	1														9
A-					1	2	2	2													7
BBB+							2	8	3												13
BBB								1	6	3											10
BBB-									4	6	2										12
BB+										1	4	2	1								8
BB											1	4	1								6
BB-													2	2							4
B+												1	1	2							4
B														1	2						3
B-																0					0
CCC+																	1				1
CCC																		0			0
CCC-																			0		0
D																				0	0
Total	0	0	1	2	6	8	5	11	13	10	7	7	5	5	2	0	1	0	0	0	83

Tabla 6.13 Rating de S&P's y Moody's (2014) Sector 'Consumo'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Los índices de desplazamiento de los *ratings* de Moody's, en cada nivel de *rating* de S&P's se muestran a continuación.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	1	0	1
A+	0	0	0	0
A	2	1	1	3
A-	4	2	4	4
BBB+	2	3	1	2
BBB	4	3	2	2
BBB-	4	2	2	0
BB+	1	4	2	2
BB	1	1	1	2
BB-	0	2	0	0
B+	3	0	0	2
B	1	0	1	0
B-	0	0	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	22	19	14	18

Tabla 6.14 Índices de desplazamiento (Sector 'Consumo')

Los índices de inflación calculados son $II = 0.0009$ y $II^* = 0.2792$. Es decir, en 2014, S&P's ha atribuido *ratings* en el sector de consumo similares o ligeramente inferiores a Moody's, a diferencia de la tendencia global. En 2018 estos índices son $II = -0.0064$ y $II^* = -0.5667$, lo que muestra el cambio experimentado en estos años, en los que S&P's se ha vuelto ligeramente menos exigente que Moody's a la hora de asignar puntuaciones a largo plazo.

El test de Wilcoxon (y el de signos) no detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en ninguno de los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2018	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	17	315,50	Rangos negativos	16	247,00
Rangos positivos	18	314,50	Rangos positivos	15	249,00
Empates	48		Empates	47	
Total	83	$p = 0.496$	Total	78	$p = 0.491$

Tabla 6.15 Contrastes de Wilcoxon. Sector 'Consumo'

Al tabular las diferencias entre puntuaciones se observa una ligera asimetría




Gráfico 6.5 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Consumo'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al comparar la distribución de las diferencias de puntuación, se tiene que ha aumentado la proporción de coincidencias (en este intervalo de tiempo), y, consecuentemente, han disminuido las diferencias.

Energía		Moody's																		Total																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																		
		Aaa	Aa	Aa	Aa	A	A	A	Baa	Baa	Baa	Ba	Ba	Ba	B	B	B	Caa	Caa		Caa	Ca																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																																
		1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2

Tabla 6.16 Rating de S&P's y Moody's (2014) Sector 'Energía'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Energía	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			2																		2
AA-			1	0																	1
A+					3																3
A						0	2														2
A-					1	1	1	2													5
BBB+							1	3	1												5
BBB								2	5	4											11
BBB-								2	6	2											10
BB+											1	1									2
BB												3		1							4
BB-													1	1							2
B+													1	1	1						3
B															2	1					3
B-														1	2	1					4
CCC+														1	1	2					4
CCC																	0				0
CCC-																		0			0
D																	1			0	1
Total	0	0	3	0	4	1	4	7	8	10	3	4	2	3	5	4	4	0	0	0	62

Tabla 6.17 Rating de S&P's y Moody's (2018) Sector 'Energía'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

En el año 2014, las valoraciones otorgadas por las dos agencias eran más heterogéneas que en 2018.

Los índices de desplazamiento de las valoraciones de Moody's, en cada nivel de *rating* de S&P's se muestran a continuación.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	2	0	0	0
AA-	3	0	1	0
A+	0	1	0	0
A	2	1	0	2
A-	0	0	3	2
BBB+	2	3	1	1
BBB	2	3	2	4
BBB-	2	1	2	2
BB+	1	2	0	1
BB	3	5	0	2
BB-	1	8	0	1
B+	6	6	1	1
B	7	9	0	1
B-	3	7	1	1
CCC+	0	5	3	0
CCC	0	0	0	0
CCC-	5	0	0	0
D	2	0	3	0
Total	41	51	17	18

Tabla 6.18 Índices de desplazamiento (Sector 'Energía')

Como puede apreciarse, se han homogeneizado las calificaciones entre las dos grandes agencias en el período entre 2014 y 2018, salvo en escalas inferiores del grado especulativo.

Los índices de inflación en 2014 son $II = 0.0207$ y $II^* = -0.0326$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = 0.0094$ y $II^* = 0.1077$.

El test de Wilcoxon (y el de signos) no detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en ninguno de los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	35	1364,50	Rangos negativos	13	227,50
Rangos positivos	42	1638,50	Rangos positivos	18	268,50
Empates	87		Empates	32	
Total	164	$p = 0.226$	Total	63	$p = 0.331$

Tabla 6.19 Contrastes de Wilcoxon. Sector 'Energía'

Al tabular las diferencias entre puntuaciones se observa una ligera asimetría que se acentúa en 2018, incrementándose las diferencias entre las puntuaciones de las dos agencias

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS




Gráfico 6.6 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Energía'

A continuación se observan las relaciones entre las puntuaciones de las dos agencias en el sector de empresas sanitarias.

Sanidad	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	1																				1
AA+	0																				0
AA		0	1	2																	3
AA-			0	3																	3
A+				0	3	1															4
A					0	1															1
A-						1	4	2													7
S&P's BBB+						1	1	3													5
BBB							3	5	4	1											13
BBB-							1	1													2
BB+										2	4										6
BB											1	2									3
BB-												1	1								2
B+														0							0
B															2	1					3

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

B-																2					2
CCC+																	0				0
CCC																		0			0
CCC-																			0		0
D																				0	0
Total	1	0	0	1	5	3	4	8	11	5	3	5	3	1	2	3	0	0	0	0	55

Tabla 6.20 Rating de S&P's y Moody's (2018) Sector 'Sanidad'

Sanidad		Moody's																			Total	
		Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3		Ca
S&P's	AAA	1																				1
	AA+		0																			0
	AA			0		3	1															4
	AA-				1	1	1															3
	A+					1	4	1														6
	A						0	0	2													2
	A-							2	1	3												6
	BBB+								1	4	1											6
	BBB									1	4	1										6
	BBB-									1	3	2	1									7
	BB+										1	2										3
	BB												2	3	1							6
	BB-												1	2	1							4
	B+														3	1						4
	B														1	2						3
	B-																0	1				1

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

CCC+																	0				0
CCC																	0				0
CCC-																		0			0
D																			0		0
Total	1	0	0	1	5	6	3	4	9	9	5	4	5	6	3	0	1	0	0	0	62

Tabla 6.21 Rating de S&P's y Moody's (2014) Sector 'Sanidad'

En el sector sanitario la situación, en 2014, de inflación de *ratings* por parte de S&P's (siempre respecto de Moody's), clara, se reproduce en 2018. Las únicas explicaciones posibles son, o bien S&P's tiene una metodología totalmente distinta a Moody's para evaluar empresas en el sector de la sanidad, lo que sería extraño, o que en este sector se produce una inflación de *ratings* clara por parte de S&P's. Sería de interés disponer de las cifras de negocio de ambas agencias con empresas del sector.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	9	0	5
AA-	0	3	0	3
A+	0	6	0	5
A	0	4	0	1
A-	0	7	0	8
BBB+	0	6	1	3
BBB	1	6	1	6
BBB-	1	4	1	0
BB+	1	0	0	4
BB	0	5	0	2

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB-	1	1	0	1
B+	0	1	0	0
B	1	0	0	1
B-	0	1	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	5	53	3	39

Tabla 6.22 Índices de desplazamiento (Sector 'Sanidad')

Los índices de inflación en 2014 son $II = -0.1351$ y $II^* = -0.6429$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.1056$ y $II^* = -0.96$.

El test de Wilcoxon (y el de signos) detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en 2014 de forma clara; de igual forma ocurre en 2018 en la detección de diferencias; resultados congruentes con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	4	54,00	Rangos negativos	5	82,50
Rangos positivos	37	807,00	Rangos positivos	33	658,50
Empates	21		Empates	17	
Total	82	$p = 0.0000002$	Total	55	$p = 0.0000003$

Tabla 6.23 Contrastes de Wilcoxon. Sector 'Sanidad'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al tabular las diferencias entre puntuaciones se observa una ligera asimetría que se acentúa en 2018, incrementándose las diferencias entre las puntuaciones de las dos agencias




Gráfico 6.7 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Sanidad'

El sector hotelero se caracteriza por tener, en general, *ratings* medios o medios-bajos, incluyendo en el grado especulativo, y por un alto grado de coincidencia entre las puntuaciones atribuidas por las dos grandes agencias. El número de empresas en las dos muestras es reducido en relación a otros sectores.

Hoteles	Moody's																			Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca
AAA	0																			0
AA+		0																		0
AA			0																	0
AA-				0																0
S&P's A+					0															0
A						0														0
A-							1													1
BBB+								0												0
BBB									2											2

1

0
1
1
0

	5	
--	---	--

	0	
	0	
	0	

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB+												0								0
BB												2	1							3
BB-													1			1				2
B+														0		1				1
B															3					3
B-																0				0
CCC+																	0			0
CCC																		0		0
CCC-																		0		0
D																			0	0
Total	0	0	0	0	0	0	0	1	2	1	2	1	1	0	5	0	0	0	0	13

Tabla 6.25 Rating de S&P's y Moody's (2014) Sector 'Hoteles'

Los índices de desplazamiento reflejan esta coincidencia en prácticamente todos los niveles de *rating*.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	0	0	0
A+	0	0	0	0
A	0	0	0	0
A-	0	0	0	0
BBB+	0	0	0	0
BBB	0	0	1	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BBB-	0	0	1	0
BB+	0	0	0	0
BB	2	0	0	1
BB-	0	2	1	0
B+	0	1	1	1
B	0	0	0	0
B-	0	0	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	2	3	4	2

Tabla 6.26 Índices de desplazamiento (Sector 'Hoteles')

Los índices de inflación en 2014 son $II = -0.0050$ y $II^* = -0.5$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = 0.0083$ y $II^* = 0.3333$.

El test de Wilcoxon (y el de signos) no se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en 2014 de forma clara; de igual forma ocurre en 2018 en la detección de diferencias; resultados congruentes con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	2	4,00	Rangos negativos	3	9,00
Rangos positivos	2	6,00	Rangos positivos	2	6,00

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Empates	9		Empates	6	
Total	13	$p = 0.5$	Total	11	$p = 0.5$

Tabla 6.27 Contrastes de Wilcoxon. Sector 'Hoteles'

Al tabular las diferencias entre puntuaciones se observa una ligera asimetría en 2014, disminuyendo las diferencias entre las puntuaciones de las dos agencias unos años más tarde.




Gráfico 6.8 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Hoteles'

El sector industrial refleja la inflación de puntuaciones atribuidas por S&P's respecto a Moody's

Industrial	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	1																				1
AA+		0																			0
AA			0																		0
AA-				1	2	1															4
A+					5	5	1														11

A					1	8	3	1												13	
A-					3	10	2													15	
BBB+						4	12	4	1											21	
BBB							5	8	10	2										25	
BBB-								5	11	2	1									19	
BB+										6	4									10	
BB										2	4	6	2							14	
BB-											1	6	2	1						10	
B+												1	1	1						3	
B														1	4					5	
B-														1	4	1				6	
CCC+																1				1	
CCC																	0		1	1	
CCC-																		0		0	
D																			2	2	
Total	1	0	0	1	8	17	18	20	17	22	12	10	13	5	4	8	2	0	0	3	101

Tabla 6.28 Rating de S&P's y Moody's (2018) Sector 'Industrial'[illegible]

17

	10	
	24	
	16	

23

		13	
--	--	----	--

	20	
	15	

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

A+	0	5	0	7
A	2	7	1	5
A-	1	8	3	2
BBB+	4	5	4	6
BBB	1	5	5	14
BBB-	1	5	5	4
BB+	0	18	0	4
BB	1	12	2	10
BB-	0	8	1	4
B+	1	6	1	1
B	2	7	0	4
B-	0	2	1	1
CCC+	1	0	0	0
CCC	1	1	0	2
CCC-	0	0	0	0
D	0	0	0	0
Total	15	95	23	68

Tabla 6.30 Índices de desplazamiento (Sector 'Industrial')

Los índices de inflación en 2014 son $II = -0.2514$ y $II^* = -0.25$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0444$ y $II^* = -0.5$.

El test de Wilcoxon (y el de signos) se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	17	884,00	Rangos negativos	23	805,00
Rangos positivos	87	4576,00	Rangos positivos	57	2435,00
Empates	92		Empates	81	
Total	196	$p = 1.5 \times 10^{-12}$	Total	181	$p = 0.00004$

Tabla 6.31 Contrastes de Wilcoxon. Sector 'Industrial'

Al tabular las diferencias entre puntuaciones se observa la asimetría asociada a la inflación de puntuaciones asociada a S&P's




Gráfico 6.9 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Industrial'

Al comparar la distribución de las diferencias de puntuación, se tiene que han disminuido las diferencias en este período de tiempo, aunque se mantienen unas diferencias claras, siendo Moody's más conservadora a la hora de atribuir puntuaciones altas.

El sector de empresas informáticas muestra una mayor dispersión en los *ratings* atribuidos por las dos agencias, con una tendencia a obtener *ratings* más moderados en el caso de Moody's

Informática	Moody's																			Total
	Aaa	Aa	Aa	Aa	A	A	A	Baa	Baa	Baa	Ba	Ba	Ba	B	B	B	Caa	Caa	Caa	
		1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	

S&P's	AAA	1																		1
	AA+		1	1																2
	AA			0	1															1
	AA-				0	1	1													2
	A+				1	5														6
	A						1	2												3
	A-						1	4												5
	BBB+							2	5	1										8
	BBB							2	13	3										18
	BBB-								1	9	2									12
	BB+										5	7	1							13
	BB										1	3	3	2						9
	BB-											1	1	1	1					4
	B+													0						0
	B													2	2					4
	B-														1	0				1
	CCC+															1	0			1
	CCC																0			0
	CCC-																	0		0
	D																		0	0
Total	1	1	1	2	6	3	8	7	15	12	8	11	5	5	4	1	0	0	0	90

[illegible]

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

	AA	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	Total
AA+	1																					1
AA	1	1																				2
AA-			0	3																		3
A+				4																		4
A			1	2	1																	4
A-					4	1																5
BBB+					1	8	1	1														11
BBB					1	9	2															12
BBB-						2	9	3														14
BB+								6	5	2												13
BB									5	6	2											13
BB-										4	2											6
B+										1	3	2										6
B												1										1
B-															0							0
CCC+																0						0
CCC																	0					0
CCC-																		0				0
D																				0		0
Total	1	2	1	0	8	2	6	10	12	12	9	10	13	7	3	0	0	0	0	0	0	96

Tabla 6.33 *Rating* de S&P's y Moody's (2014) Sector 'Informática'

Los índices de desplazamiento muestran la tendencia de S&P's de inflar las puntuaciones atribuidas a empresas informáticas, aunque en menor medida que en el caso de empresas industriales.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	1
AA	1	0	0	1
AA-	0	3	0	3
A+	0	0	1	0
A	1	1	0	2
A-	0	1	1	0
BBB+	1	3	2	1
BBB	2	2	1	3
BBB-	2	3	1	2
BB+	0	9	0	9
BB	0	10	1	7
BB-	0	2	1	3
B+	1	2	0	0
B	0	0	2	0
B-	0	0	1	0
CCC+	0	0	1	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	8	36	12	32

Tabla 6.34 Índices de desplazamiento (Sector 'Informática')

Los índices de inflación en 2014 son $II = -0.0165$ y $II^* = 0$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0785$ y $II^* = -0.3913$.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

El test de Wilcoxon (y el de signos) se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	8	140,00	Rangos negativos	14	248,00
Rangos positivos	31	640,00	Rangos positivos	27	613,00
Empates	57		Empates	49	
Total	96	$p = 0.000044$	Total	196	$p = 0.005$

Tabla 6.35 Contrastes de Wilcoxon. Sector 'Informática'

Al tabular las diferencias entre puntuaciones se observa la asimetría asociada a la inflación de puntuaciones asociada a S&P's.




Gráfico 6.10 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Informática'

Al comparar la distribución de las diferencias de puntuación, se tiene que han disminuido ligeramente las diferencias en este período de tiempo, aunque se mantienen unas diferencias claras, siendo Moody's más conservadora a la hora de atribuir puntuaciones altas.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

En el sector de medios de comunicación la distribución de los *ratings* es similar en las dos agencias. Además, estas puntuaciones suelen tomar valores centrales, tanto en el rango de productos de inversión como especulativos con unos cambios en los últimos años tendentes al deterioro de los valores asignados.

Medios		Moody's																				Total
		Aaa	Aa	Aa	Aa	A	A	A	Baa	Baa	Baa	Ba	Ba	Ba	B	B	B	B	Caa	Caa	Caa	
			1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3		
S&P's	AAA	0																				0
	AA+		0																			0
	AA			0																		0
	AA-				0																	0
	A+					0																0
	A						0															0
	A-							3														3
	BBB+								4													4
	BBB									4												4
	BBB-										1	2	1									4
	BB+											0										0
	BB												3	1								4
	BB-													1	0	2						3
	B+															0						0
	B														1		1					2
	B-																	2				2
	CCC+																		0			0
CCC																			0		0	
CCC-																				0	0	

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

D																					0	0
Total	0	0	0	0	0	0	3	4	5	2	1	4	2	2	1	2	0	0	0	0	0	26

Tabla 6.36 Rating de S&P's y Moody's (2018) Sector 'Medios'

Medios	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				0																	0
A+					0																0
A						0															0
A-							1														1
BBB+								4													4
BBB								2	5												7
BBB-										4											4
BB+											3		1								4
BB												1	1								2
BB-												2	3	1							6
B+														1	1						2
B															2	1					3
B-													1			1	1				3
CCC+																	2				2
CCC																		0			0
CCC-																			0		0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

D																				0	0
Total	0	0	0	0	0	0	1	6	5	4	3	3	6	2	3	2	3	0	0	0	38

Tabla 6.37 Rating de S&P's y Moody's (2014) Sector 'Medios'

La distribución de los índices de desplazamiento refleja la homogeneidad en las puntuaciones asignadas por las dos agencias.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	0	0	0
A+	0	0	0	0
A	0	0	0	0
A-	0	0	0	0
BBB+	0	0	0	0
BBB	0	0	1	0
BBB-	0	0	1	1
BB+	0	2	0	0
BB	0	1	0	1
BB-	2	1	1	2
B+	0	1	0	0
B	0	1	2	0
B-	3	1	0	0
CCC+	0	0	0	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	5	7	5	4

Tabla 6.38 Índices de desplazamiento (Sector 'Medios')

Los índices de inflación en 2014 son $II = -0.005$ y $II^* = -0.1667$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0025$ y $II^* = -0.6667$.

El test de Wilcoxon (y el de signos) no se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	5	31,00	Rangos negativos	3	14,00
Rangos positivos	6	35,00	Rangos positivos	4	14,00
Empates	27		Empates	19	
Total	38	$p = 0.5$	Total	26	$p = 0.617$

Tabla 6.39 Contrastes de Wilcoxon. Sector 'Medios'

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS




Gráfico 6.11 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Medios'

Al comparar la distribución de las diferencias de puntuación, se tiene que han disminuido ligeramente en este período de tiempo.

La distribución de puntuaciones en el sector de minería muestra una homogeneidad entre las dos agencias como se aprecia en los cuadros siguientes.

Minería	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				0																	0
A+					0																0
S&P's A						8															8
A-							1	1													2
BBB+								4													4
BBB									6	2											8
BBB-									2	4	1										7
BB+										2	0	1									3

BB												2	0							2
BB-												2	2	1						5
B+														0						0
B														1	0					1
B-															0					0
CCC+																0				0
CCC																	0			0
CCC-																		0		0
D																			0	0
Total	0	0	0	0	0	8	1	5	8	8	3	3	2	2	0	0	0	0	0	40

		Moody's																		Total	
		Aaa	Aa	Aa	Aa	A	A	A	Baa	Baa	Baa	Ba	Ba	Ba	B	B	B	Caa	Caa		Caa
S&P's	AAA	0																			0
	AA+		0																		0
	AA			0																	0
	AA-				0																0
	A+					1															1
	A						0		1												1
	A-							2													2
	BBB+								0	1											1
	BBB									3	3										6
	BBB-									1	1	2									4
	BB+										1	5									6
	BB											3	1	1							5

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB-												2	0							2
B+													0							0
B												1		0						1
B-															1					1
CCC+																0				0
CCC																	0			0
CCC-																		0		0
D																			0	0
Total	0	0	0	0	1	0	2	1	5	5	10	3	2	0	0	1	0	0	0	30

Tabla 6.41 Rating de S&P's y Moody's (2014) Sector 'Minería'

Los índices de desplazamiento confirman la homogeneidad de las puntuaciones atribuidas por las dos agencias.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	0	0	0
A+	0	0	0	0
A	0	2	0	0
A-	0	0	0	1
BBB+	0	1	0	0
BBB	1	3	2	2
BBB-	1	2	2	1
BB+	1	0	2	1

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB	3	1	2	0
BB-	2	0	2	1
B+	0	0	0	0
B	2	0	1	0
B-	0	0	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	10	9	11	6

Tabla 6.42 Índices de desplazamiento (Sector 'Minería')

Los índices de inflación en 2014 son $II = -0.0167$ y $II^* = -0.0357$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = 0.0072$ y $II^* = 0.2222$.

Con el test de Wilcoxon (y el de signos) no se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	8	68,00	Rangos negativos	9	72,00
Rangos positivos	8	68,00	Rangos positivos	6	48,00
Empates	14		Empates	25	
Total	30	$p = 0.552$	Total	40	$p = 0.304$

Tabla 6.43 Contrastes de Wilcoxon. Sector 'Minería'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones.




Gráfico 6.12 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Minería'

La distribución de los *ratings* en el sector de industrias papeleras se muestra en las tablas siguientes, en el que las diferencias son pequeñas y se observa que los *ratings* atribuidos a empresas del sector se concentran en valores centrales.

Papeleras	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				0																	0
A+					0																0
A						0															0
A-							0														0
BBB+								0	1												1
BBB									5												5
BBB-										4											4
BB+											5	2									7
BB											1	2									3

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB-												1	2	0									3
B+														0									0
B															0								0
B-																0							0
CCC+																	0						0
CCC																		0					0
CCC-																			0				0
D																				0			0
Total	0	0	0	0	0	0	0	0	6	4	7	6	0	0	0	0	0	0	0	0	0	0	23

Tabla 6.44 Rating de S&P's y Moody's (2018) Sector 'Papeleras'

Papeleras		Moody's																			Total
		Aaa	Aa 1	Aa 2	Aa 3	A 1	A 2	A 3	Baa 1	Baa 2	Baa 3	Ba 1	Ba 2	Ba 3	B 1	B 2	B 3	Caa 1	Caa 2	Caa 3	
S&P's	AAA	0																			0
	AA+		0																		0
	AA			0																	0
	AA-				0																0
	A+					0															0
	A						0														0
	A-							0													0
	BBB+								0	1											1
	BBB									3	1										4
	BBB-									1	1										2
	BB+											3									3
	BB												5	2							7
BB-													3							3	

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	Total
B+														1							1
B														1							1
B-															0						0
CCC+																0					0
CCC																	0				0
CCC-																		0			0
D																			0		0
Total	0	0	0	0	0	0	0	0	5	2	3	5	5	1	1	0	0	0	0	0	22

Tabla 6.45 *Rating* de S&P's y Moody's (2014) Sector 'Papeleras'

Los índices de desplazamiento confirman lo que se observa en las tablas anteriores, es decir, la homogeneidad en la distribución de ambas agencias.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	0	0	0
A+	0	0	0	0
A	0	0	0	0
A-	0	0	0	0
BBB+	0	1	0	1
BBB	1	1	0	0
BBB-	1	0	0	0
BB+	0	0	0	2
BB	0	2	1	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB-	0	0	4	0
B+	0	0	0	0
B	0	0	0	0
B-	0	0	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	2	4	5	3

Tabla 6.46 Índices de desplazamiento (Sector 'Papeleras')

Los índices de inflación en 2014 son $II = -0.0057$ y $II^* = 1$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0015$ y $II^* = 0.25$.

Con el test de Wilcoxon (y el de signos) no se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	2	7,00	Rangos negativos	4	15,50
Rangos positivos	4	14,00	Rangos positivos	3	10,50
Empates	16		Empates	16	
Total	22	$p = 0.344$	Total	23	$p = 0.383$

Tabla 6.47 Contrastes de Wilcoxon. Sector 'Papeleras'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones otorgadas por las dos agencias en los dos períodos de tiempo considerados.




Gráfico 6.13 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Papeleras'

En las industrias químicas, los *ratings* obtenidos por las empresas se concentran alrededor de valores centrales, con una cierta variabilidad de una agencia respecto de la otra.

Químicas	Moody's																				Total
	Aaa	Aa 1	Aa 2	Aa 3	A 1	A 2	A 3	Baa 1	Baa 2	Baa 3	Ba 1	Ba 2	Ba 3	B 1	B 2	B 3	Caa 1	Caa 2	Caa 3	Ca	
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				0																	0
A+					0																0
A						4															4
A-							2	1													3
BBB+							1	4	2												7
BBB									6	2											8
BBB-								1	2	1	1										5
BB+										1	1										2

[illegible][illegible]

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB-													1	0							1
B+													3	1							4
B															0						0
B-																0					0
CCC+																	0				0
CCC																		0			0
CCC-																			0		0
D																				0	0
Total	0	0	0	0	1	6	2	5	10	6	5	3	3	1	0	0	0	0	0	0	42

Tabla 6.49 Rating de S&P's y Moody's (2014) Sector 'Químicas'

Los índices de desplazamiento resumen la información anterior, corroborando que las diferencias existentes en 2014 se difuminan unos años más tarde.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	0	0	0
A+	0	2	0	0
A	0	0	0	0
A-	0	1	0	1
BBB+	1	5	1	2
BBB	1	3	1	2
BBB-	1	2	1	3
BB+	0	0	1	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB	1	0	0	0
BB-	1	0	0	0
B+	3	0	2	0
B	0	0	0	0
B-	0	0	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	0	0
D	0	0	0	0
Total	8	13	6	8

Tabla 6.50 Índices de desplazamiento (Sector 'Químicas')

Los índices de inflación en 2014 son $II = -0.0097$ y $II^* = -0.4444$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0024$ y $II^* = 0.0571$.

Con el test de Wilcoxon (y el de signos) no se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en los dos años, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	9	72,00	Rangos negativos	5	30,00
Rangos positivos	11	118,00	Rangos positivos	7	48,00
Empates	23		Empates	25	
Total	42	$p = 0.162$	Total	27	$p = 0.307$

Tabla 6.51 Contrastes de Wilcoxon. Sector 'Químicas'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones otorgadas por las dos agencias en los dos períodos de tiempo considerados, con una tendencia a ser más coincidentes a medida que pasa el tiempo.




Gráfico 6.14 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Químicas'

Las puntuaciones de las empresas del sector comercial se distribuyen a lo largo del conjunto de *ratings*, tanto del modo inversión como del especulativo, con una cierta variabilidad entre las calificaciones atribuidas por las dos agencias.

Comerciales	Moody's																				Total
	Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca	
AAA	0																				0
AA+		0																			0
AA			1																		1
AA-				0	1		1														2
A+				1	0	1	1														3
A						1															1
A-						2	0														2
BBB+							1	3		1											5
BBB								4	7	2											13
BBB-										2											2

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB+											2												2
BB										1		5											6
BB-												2	2										4
B+												1		1									2
B													1	1	5	2							9
B-																0							0
CCC+																	0						0
CCC																	2	1					3
CCC-																			0				0
D																				1			1
Total	0	0	1	0	2	4	3	7	8	5	2	8	3	2	5	2	2	1	0	1			56

Tabla 6.52 Rating de S&P's y Moody's (2018) Sector 'Comerciales'

Comerciales	Moody's																				Total
	Aaa	Aa	Aa	Aa	A	A	A	Baa	Baa	Baa	Ba	Ba	Ba	B	B	B	Caa	Caa	Caa	Ca	
AAA	0																				0
AA+		0																			0
AA			1																		1
AA-				0	1			1													2
A+					1		1														2
A						2															2
A-						1	4	2													7
BBB+								3	2												5
BBB								6	2												8
BBB-								1	3	2											6
BB+										4	1										5

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB									1			2	3							6
BB-													2							2
B+													1	3						4
B													1		0					1
B-															2	1				3
CCC+																2				2
CCC																	0			0
CCC-																		0		0
D																			0	0
Total	0	0	1	0	2	3	5	6	10	5	6	3	7	3	0	2	3	0	0	56

Tabla 6.53 Rating de S&P's y Moody's (2014) Sector 'Comerciales'

Los índices de desplazamiento muestran una tendencia de S&P's a otorgar puntuaciones ligeramente mayores en 2014, pero que se homogenizan al transcurrir unos años.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0
AA-	0	5	0	4
A+	0	2	1	3
A	0	0	0	0
A-	1	2	2	0
BBB+	0	2	1	1
BBB	1	2	0	2
BBB-	1	2	0	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BB+	0	1	0	0
BB	3	3	2	0
BB-	0	0	2	0
B+	1	0	2	0
B	2	0	3	2
B-	0	1	0	0
CCC+	0	0	0	0
CCC	0	0	2	0
CCC-	0	0	0	0
D	0	0	0	0
Total	9	20	15	12

Tabla 6.54 Índices de desplazamiento (Sector 'Comercial')

Los índices de inflación en 2014 son $II = -0.0539$ y $II^* = 0.2615$, habiéndose convertido en positivos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0245$ y $II^* = -1.4$.

Con el test de Wilcoxon (y el de signos) se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en 2014, pero no en 2018, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	5	65,50	Rangos negativos	15	184,50
Rangos positivos	16	165,50	Rangos positivos	9	115,50
Empates	35		Empates	32	
Total	56	$p = 0.036$	Total	56	$p = 0.166$

Tabla 6.55 Contrastes de Wilcoxon. Sector 'Comercial'

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones otorgadas por las dos agencias en 2018, con una tendencia a ser más coincidentes a medida que pasa el tiempo.




Gráfico 6.15 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Comercial'

La distribución de los *ratings* en el sector de telecomunicaciones para las dos muestras, se relacionan en las tablas siguientes. Las calificaciones se distribuyen sobre una gran parte del modo de inversión y del modo especulativo, con una cierta variabilidad entre las dos agencias.

	Moody's																				Total
	Aaa	Aa 1	Aa 2	Aa 3	A 1	A 2	A 3	Baa 1	Baa 2	Baa 3	Ba 1	Ba 2	Ba 3	B 1	B 2	B 3	Caa 1	Caa 2	Caa 3	Ca	
Telecomunicaciones																					
AAA	0																				0
AA+		0																			0
AA			0																		0
AA-				1																	1
A+					0																0
A						1															1
A-							1	3													4
BBB+								5	2												7
BBB									3	2											5

4

0		0
		0
		1
		6
		2
		0
		0
		0
0		2
	0	0
0	0	33

es'

		Total
aa	Ca	
3		0
		0
		0
		4
		2
		2
		6
		9

BBB							1		5	2	1									9
BBB-								1		2										3
BB+											7									7
BB											3	1	2							6
BB-												1	1	1	2					5
B+													1	1	1	1				4
B														2	1		1			4
B-													1		1	3				5
CCC+																0				0
CCC																	0			0
CCC-																		0		0
D																			0	0
Total	0	0	0	5	1	3	5	7	9	4	11	2	4	3	5	3	3	1	0	0

Los índices de desplazamiento muestran la tendencia, en 2014, de S&P's, de otorgar mayores calificaciones que Moody's, tendencia que se atempera en 2018.

309

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

BBB+	0	4	0	2
BBB	2	4	1	2
BBB-	2	0	1	4
BB+	0	0	0	0
BB	3	2	0	0
BB-	1	5	0	1
B+	1	3	4	3
B	0	4	0	0
B-	2	3	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	0	0	2	0
D	0	0	0	0
Total	14	27	9	12

Tabla 6.58 Índices de desplazamiento (Sector 'Telecomunicaciones')

Los índices de inflación en 2014 son $II = -0.007$ y $II^* = 0.05$, habiéndose convertido en negativos ambos (debido a la menor cotización de S&P's en los niveles inferiores del grado especulativo) en 2018, siendo $II = -0.0061$ y $II^* = -0.075$.

Con el test de Wilcoxon (y el de signos) se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en 2014, pero no en 2018, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	11	184,00	Rangos negativos	8	98,00

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Rangos positivos	21	344,00	Rangos positivos	11	92,00
Empates	34		Empates	21	
Total	66	$p = 0.062$	Total	40	$p = 0.443$

Tabla 6.59 Contrastes de Wilcoxon. Sector 'Telecomunicaciones'

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones otorgadas por las dos agencias en 2018, con una tendencia a ser más coincidentes a medida que pasa el tiempo.




Gráfico 6.16 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Telecomunicaciones'.

La distribución de los *ratings* en el sector de 'Utilidades' o servicios públicos, ha cambiado de su estructura en 2014 a la que tiene en 2018, con una concentración de las calificaciones en los niveles de inversión no elevados.

		Moody's																			Total
		Aaa	Aa1	Aa2	Aa3	A1	A2	A3	Baa1	Baa2	Baa3	Ba1	Ba2	Ba3	B1	B2	B3	Caa1	Caa2	Caa3	Ca
S&P's	AAA	0																			0
	AA+		0																		0
	AA			0																	0
	AA-				0																1

A+					1															0
A					1	2	1	1												1
A-							4	15	3											4
BBB+							3	13	25	1	1									7
BBB								2	12	3										5
BBB-								1	2	3										4
BB+											0									0
BB											1	0								0
BB-													0	3						1
B+														0						6
B															0					2
B-																0				0
CCC+																	0			0
CCC																		0		0
CCC-																		0		2
D																			0	0
Total	0	0	0	0	2	2	8	32	42	7	2	0	0	3	0	0	0	0	0	98

[illegible]

A					4	2	3	4												13	
A-					3	6	20	10	4											43	
BBB+						2	8	17	5	2	1									35	
BBB							3	18	11	6										38	
BBB-								3	6	17	1	1								28	
BB+										6	5	1								12	
BB										2	1	4	2							9	
BB-												2	4							6	
B+													2	2	1					5	
B															0					0	
B-																1	1			2	
CCC+																	0			0	
CCC																		0		0	
CCC-																	2		1	3	
D																			0	0	
Total	0	0	1	8	10	11	36	52	26	33	8	8	8	2	1	1	3	0	1	0	209

Tabla 6.61 *Rating* de S&P's y Moody's (2014) Sector 'Utilidades'

Partiendo de una distribución más homogénea en 2014, se detecta una inflación de *ratings* en 2018 por parte de S&P's, tendencia contraria a la de otros sectores. Los índices de desplazamiento para cada nivel de puntuación muestran este fenómeno.

S&P's vs Moody's	2014		2018	
	S+	S-	S+	S-
AAA	0	0	0	0
AA+	0	0	0	0
AA	0	0	0	0

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

AA-	0	2	0	0
A+	6	5	0	0
A	4	11	1	3
A-	12	18	0	21
BBB+	12	12	3	30
BBB	12	6	4	3
BBB-	12	3	4	0
BB+	6	1	0	0
BB	5	2	1	0
BB-	2	0	0	3
B+	2	1	0	0
B	0	0	0	0
B-	0	1	0	0
CCC+	0	0	0	0
CCC	0	0	0	0
CCC-	4	0	0	0
D	0	0	0	0
Total	77	62	13	60

Tabla 6.62 Índices de desplazamiento (Sector 'Utilidades')

Los índices de inflación en 2018 son $II = -0.0031$ y $II^* = -0.5683$, y en 2014, es $II = -0.012$ y $II^* = 0.268$.

Con el test de Wilcoxon (y el de signos) se detectan diferencias significativas en las calificaciones atribuidas por las dos agencias en 2014 en las que S&P's produce valores más reducidos, pero en 2018 se produce el fenómeno contrario, generándose inflación de puntuaciones, resultado congruente con la descripción de índices de desplazamiento y de inflación.

Moody's - S&P's 2014	<i>n</i>	Suma de rangos	Moody's - S&P's 2018	<i>n</i>	Suma de rangos
Rangos negativos	74	184,00	Rangos negativos	10	316,00
Rangos positivos	47	344,00	Rangos positivos	53	1700,00
Empates	88		Empates	35	
Total	209	$p = 0.037$	Total	98	$p = 2.7 \times 10^{-8}$

Tabla 6.63 Contrastes de Wilcoxon. Sector 'Utilidades'

Al tabular las diferencias entre *ratings* se observa la homogeneidad de puntuaciones otorgadas por las dos agencias en 2018, con una tendencia a ser más coincidentes a medida que pasa el tiempo.




Gráfico 6.17 Diferencias de puntuación entre S&P's y Moody's (2014 y 2018) Sector 'Utilidades'

6.5. Resumen de comparaciones

En definitiva, se observan diversos fenómenos al estudiar los *ratings* atribuidos por las dos principales agencias en el intervalo de tiempo entre 2014 y 2018. Globalmente, se puede afirmar que S&P's tiende a asignar puntuaciones más elevadas que Moody's, es decir que se produce el fenómeno conocido como 'inflación de *ratings*'.

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

En la tabla siguiente se han resumido la evolución de las medianas de los *ratings* y las medias (de la codificación, aunque es en realidad es ordinal) de estas puntuaciones.

Los valores inferiores corresponden a los *ratings* más fiables (con menos probabilidad de fallido); el dígito 1 corresponde a los *ratings* AAA de S&P's, o Aaa de Moody's, el 2 a las respectivas calificaciones AA o Aa1 y así sucesivamente hasta el último escalón de los niveles de inversión (BBB- o Baa3, nivel 10), y a partir del nivel 11 (BB+ o Ba1) hasta el nivel 20 (D o Ca).

	2014					2018				
	Frec.	S&P's		Moody's		Frec.	S&P's		Moody's	
		Media	Mediana	Media	Mediana		Media	Mediana	Media	Mediana
Consumo	94	9.30	9	9.30	9	105	8.72	9	8.72	9
Energía	189	11.73	12	11.78	12.5	91	10.33	10	10.38	10
Sanidad	71	8.95	9	9.74	10	73	8.71	9	9.33	9
Hoteles'	20	12.08	12	12.15	12	21	11.82	13	11.73	13
Industrial	251	10.13	10	10.53	11	256	9.53	9	9.91	9
Informática	116	9.5	10	9.79	10	126	9.34	9	9.55	10
Medios	52	11.65	11	11.66	11.5	66	10.69	10	10.69	10
Minería	37	10.33	10.5	10.33	11	52	9.32	9	9.25	9
Papeleras	24	11.36	12	11.45	12	28	10.95	11	10.57	11
Química	44	9.14	9	9.26	9	46	9.70	9	9.78	9
Comercial	68	10.00	10	10.21	10	71	10.80	10	10.70	10
Teleco.	86	10.20	10	10.39	10	48	10.68	10.5	10.69	11
Utilidades	272	8.74	8	8.61	8	128	8.13	8	8.63	9
Total	1324	9.98	10	10.14	10	1111	9.52	9	9.70	9

Tabla 6.64 Resumen de *ratings* de S&P's y Moody's en 2014 y 2018

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

Además se dispone de la tabla siguiente resumen de la comparación de las dos agencias. La probabilidad límite, p , es la del test de Wilcoxon, unilateral, para contrastar si la distribución de calificaciones de S&P's están 'infladas' respecto de las de Moody's. Los índices de inflación, II , para los que valores negativos pretenden medir el grado de inflación de las puntuaciones de Moody's respecto de S&P's, y los índices de desplazamiento, $S+$ y $S-$, que indican, respectivamente, el número ponderado de empresas con *rating* de Moody's más o menos alto que el de S&P's.

	2014					2018				
	S&P's vs Moody's					S&P's vs Moody's				
	p	II	II^*	$S+$	$S-$	p	II	II^*	$S+$	$S-$
Consumo	0.496	-0.0009	0.2792	22	19	0.491	-0.0064	-0.5667	14	18
Energía	0.226	0.0207	-0.0326	41	51	0.331	0.0094	0.1077	17	18
Sanidad	0.000	-0.1350	-0.6429	5	53	0.000	-0.1056	-0.9600	3	39
Hoteles'	0.500	-0.0050	-0.5000	3	2	0.500	0.0083	0.3333	4	2
Industrial	0.000	-0.2514	-0.2500	15	95	0.000	-0.0444	-0.5000	23	68
Informática	0.000	-0.0165	0.0000	8	36	0.005	-0.0785	-0.3913	12	32
Medios	0.500	-0.0050	-0.1667	5	7	0.617	0.0026	0.6667	5	4
Minería	0.552	-0.0167	-0.0357	10	9	0.304	0.0072	0.2222	11	6
Papeleras	0.344	-0.0057	1.0000	2	4	0.383	-0.0015	0.2500	5	3
Química	0.162	-0.0097	-0.444	8	13	0.307	-0.0024	0.0571	6	8
Comercial	0.036	-0.0539	0.2615	9	20	0.166	-0.0245	1.400	15	12
Teleco.	0.062	-0.0070	0.0500	14	27	0.443	-0.0061	-0.0750	9	12
Utilidades	0.037	-0.0031	-0.5683	77	62	0.000	-0.0120	0.2680	13	60

Tabla 6.65 Resumen de comparaciones de S&P's y Moody's en 2014 y 2018


Los *ratings* tienden a homogeneizarse en 2018, respecto a 2014. En aquellos sectores donde las diferencias de calificaciones son significativas, como en sanidad, industrial, informática, y, en menor medida, el comercial, telecomunicaciones y utilidades, en

VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS

2014, y en sanidad, industrial, informática y utilidades en 2018, se tienen valores negativos del índice de inflación, es decir que las calificaciones otorgadas por S&P's están por encima de las de Moody's, y tiende a aproximarse a cero en 2018, correspondiente a una tendencia detectada de homogeneizarse las calificaciones de las dos agencias con el tiempo. El sector de utilidades se comporta de modo distinto: siendo más homogéneo inicialmente, su tendencia es hacia la diferenciación.

Globalmente ambas agencias han evolucionado hacia una mayor calificación crediticia de sus clientes, lo que es lógico ya que compiten por atraer a mayor número de empresas y de emisores de activos, y además lo han hecho en prácticamente los mismos desfases. Es decir, que la inflación de calificaciones es claramente observable, aunque también cabe atribuir parte de esta variación a una mejora general de la economía mundial.

A nivel sectorial, con la muestra de empresas correspondientes a 2014, la evolución de los *ratings* se muestra en los gráficos en caja siguientes para las dos agencias. Destaca la similitud de las calificaciones en cada sector (aunque se han estudiado las diferencias).



VI. COMPARACIÓN DE PUNTUACIONES DE AGENCIAS




Gráfico 6.18 Evolución sectorial de los *ratings* en 2014 para las dos agencias

En la comparación con la muestra de 2018 de los *ratings* sectoriales, de nuevo se aprecia la similitud en las calificaciones, y la coincidencia de las empresas que se separan del resto en su sector.

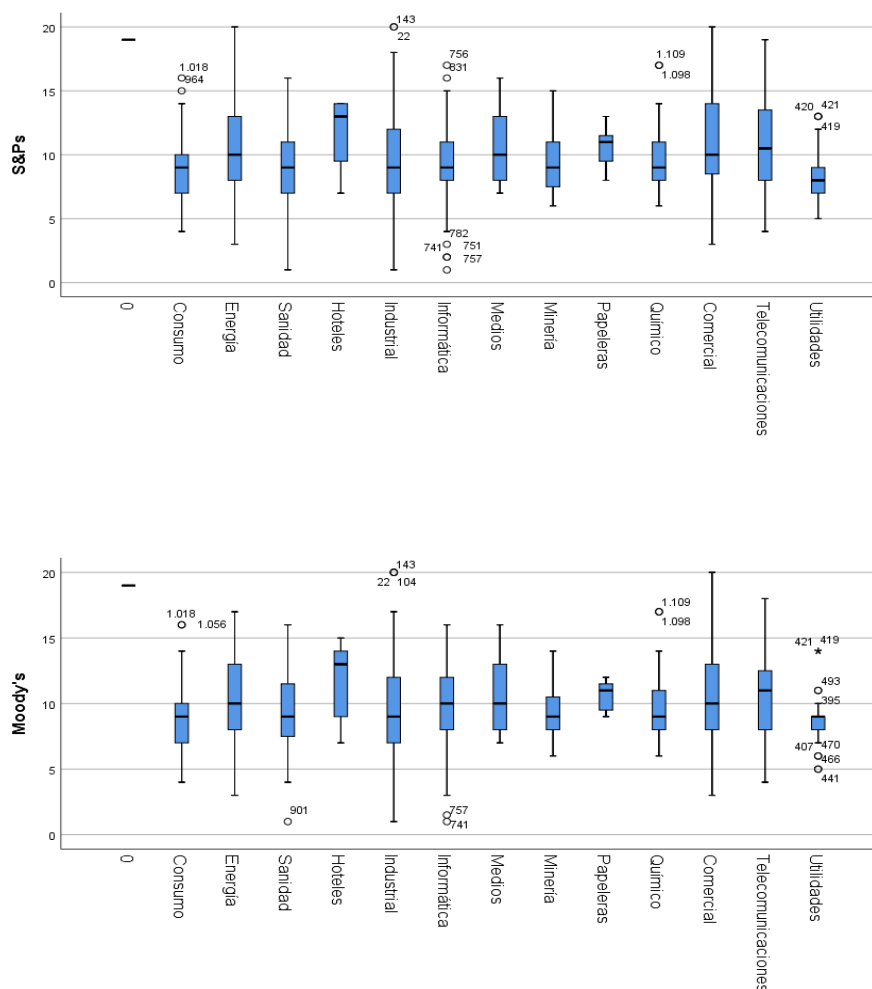


Gráfico 6.19 Evolución sectorial de los *ratings* en 2018 para las dos agencias

En un período de cuatro años se ha producido una mejora de los *ratings* en casi medio punto para las dos agencias. Y esto no puede deberse solo a la evolución del ciclo económico, sino que es reflejo de una tendencia hacia asignar puntuaciones que satisfagan más a los emisores. En el sector de ‘Consumo’ la evolución de ambas agencias es idéntica prácticamente, así como en el sector de las empresas energéticas. En el sector de empresas relacionadas con la sanidad y en el sector hotelero, es Moody’s la agencia que ha mejorado más las calificaciones. En el sector industrial, las mejoras de las calificaciones son prácticamente idénticas. En otros sectores, como el de las empresas informáticas, se ha producido una convergencia en las puntuaciones de las dos agencias. Para las empresas relacionadas con los medios de comunicación, prácticamente las dos agencias han subido un nivel en los *ratings* de sus clientes, así como para las empresas mineras. En las papeleras, es Moody’s la que ha incrementado notablemente las puntuaciones de sus clientes, duplicando la proporción de S&P’s. En el sector comercial es S&P’s la que ha mejorado casi en un nivel el *rating* de sus clientes, casi el doble que Moody’s. En empresas de telecomunicaciones, S&P’s ha mejorado más que Moody’s las calificaciones crediticias, mientras que en el sector de utilidades o servicios públicos, Moody’s ha estabilizado sus puntuaciones, mientras que S&P’s las ha empeorado significativamente.

Es decir, las dos agencias han tendido a favorecer las calificaciones de sus clientes, en un grado similar, por lo que, al partir de niveles distintos, la diferencia entre las dos agencias se mantiene en el tiempo: Moody’s es más rigurosa a la hora de calificar de forma excesivamente favorable a las empresas a las que evalúa, mientras que S&P’s tiende a asignar puntuaciones más altas, reflejo de su evolución histórica, y del posible deseo de atraer clientes de su más directo competidor.

También se observa una posible confluencia de las dos agencias en relación a empresas calificadas de forma distinta. En algunos sectores, como el comercial, el de telecomunicaciones o el de utilidades, las ‘correcciones’ realizadas entre 2014 y 2018 pueden inducir a pensar que, una vez detectadas las diferencias en las calificaciones de una empresa por parte de las dos agencias, se produce una reacción de corrección, que a

veces, en el caso de estos tres sectores, es una sobre-reacción, al invertirse el signo de las diferencias en un período tan corto.

Es decir, que además del fenómeno de inflación de *ratings*, se observa otro más inquietante en cuanto a la fiabilidad de los *ratings*: las correcciones inducidas en las calificaciones de una agencia al observar unas desviaciones sistemáticas respecto a las calificaciones otorgadas por la otra. Estaríamos, en este caso, en una situación de ‘calificaciones correladas artificialmente’. Lógicamente las calificaciones obtenidas por una agencia sobre un mismo grupo de empresas o productos financieros, están relacionadas con las calificaciones que las otras agencias realizan sobre estos mismos entes, pues teóricamente miden el riesgo de fallidos financieros y se basan en información común: los estados contables e información financiera sobre las empresas (además de la denominada ‘información cualitativa’), lo que implica relación en los resultados finales. Pero lo que no sería admisible es que, usasen las calificaciones otorgadas por otras agencias para modificar sus propias calificaciones. Esta situación originaría lo que podríamos calificar como ‘riesgos correlacionados’ asociados a esta confluencia de información y de intereses.

Para investigar este fenómeno sería preciso introducir la posible motivación de interés económico asociado a las cuotas que cobran ambas agencias a cada una de las empresas para ser evaluadas, y recoger los intervalos de tiempo entre correcciones de puntuaciones en empresas que hayan sido evaluadas por ambas agencias y que hayan originado *ratings* distintos.

VII. CONCLUSIONES

According to the actual regulation of Doctoral studies, in their International grade, the conclusions are written in English.

7.1. Conclusions

7.2. Future developments

7.1. CONCLUSIONS

Credit ratings are formulated as opinions about the situation of the creditworthiness of a company and its willingness as an obligator to meet its financial commitments. Nowadays the growing regulatory reliance on ratings, that are compulsory on many financial operations, produce curious effects:

- Something that the own creators of the ratings present as mere opinions, are transformed in legal requirements for issuers or corporations and, in many cases, in compulsory conditions for investors
- Investors, in fact, are outsourcing the evaluation of credit risk to justify their decisions.

Statistical methods have been used in the past to obtain the probability of default of corporations, as an alternative to published figures by the main rating agencies, with mixed results.

Today the availability of large data bases of company's economic and financial data make possible the use of Artificial Intelligence methods to process large or very large sets of data and, either, create models to estimate the probability of default of firms, or to reproduce the rating scale attributed to them by the main rating agencies.

A rating is reported with a unique ordinal figure: the rating assigned to a company or to a financial product. In mathematical Statistics, the absence of loss of information due to the reduction of dimension when processing a sample, is called ‘sufficiency’, but there seems not to be very academic interest in evaluating the ‘sufficiency’ of the rates attributed by CRA’s.

In fact, it is not surprising that, from time to time, ‘outliers’ such as the events associated to Enron, Parmalat, Lehman,... arouse, leading to substantial loses borne by investors, employees, customers of firms, and pension funds holders; and this leads to questioning the agencies precision and ways of summarizing the financial and economic information.

It is difficult to deal with the opacity of the credit rating agencies when trying to find out the motivations of these firms to obtain and change their ratings, as they are supposed to be accurate and stable. In spite of that, it seems that the pattern of rating changes over the last decades suggests that ratings agencies behave in more complex ways, perhaps as a response to the incentives of the rating business.

Whatever the motivations are, surely, the methodology that produces better results in forecasting is based on Artificial Neural Networks, such as the Multi-Layer Perceptron as we have analyzed here. Two samples of a large number of firms are used to estimate predictive models. The exogenous variables are clustered in several groups: some linked to the size of the company, such as capital, equity; some others associated to the activity: sales, debts, profits, cash flow. Also some leverage factors such ratios of debt over capital, or to total assets. Profit related variables are also introduced; for example, profits, or ratios such as EBITDA o ROE. Fifteen variables were recorded for each company, both in 2018 (last year available) and 2014, using a sampling procedure in Bloomberg companies data-base, and eighth financial ratios were obtained as well as the cash flow. The first sample is of over one thousand three hundreds companies and the second is formed by over one thousand and a hundred firms, not all coincident with the

first. In fact, data are available for the time spans 2014-18 and 2010-14. Also, the ordinal ratings of S&P's and Moody's are included for most of the firms, that are distributed in the most important sectors of the global economy: consumption, energy, health, hotels, industrial, informatics, media, mining, paper, chemical, commercial, telecommunications and utilities firms.

The average and median values of each variable and ratio used, are related to the rating obtained by both agencies, but their individual behaviour cannot be used as a predictor of the firm's rating. The ratio Debt/EBITDA is considered the most important, followed by the market value and the cash flow. Some ratios related to debt are also taken into account.

Some of these alternatives to review are market implied ratings e.g. bonds/equity pricing information, Credit Default Swaps spreads; and accountancy based measures such as profitability and leverage ratios. Moreover, it would be convenient to include in the model external variables related somehow with different sources of risk, there are internal risk factors in a company that may have an impact on the balance sheet, profit and loss account and, consequently, ratios and metrics if they are not well managed; at the same time also external risk factors between different companies within the same sector could have an impact and affect them.

Multivariate Statistical Methods, such as Discriminant Analysis cannot grasp the non-linearity involved in the creation of an ordinal scale. On the other hand, econometric models or dependent ordinal variables models are not easy to specify, so they usually are not able to reproduce ratings with a reasonable accuracy. Logit models have also limited accuracy in predicting ratings unless they are used for a binary classification in investment and non investment grades.

Artificial neural networks achieve a greater accuracy in forecasting the full range of ratings levels.

In point 5.6 a summary of the forecasting results is presented.

- For binary forecasting, logit models produces around 90% of correct forecasts (in investment or non investment grades), both for S&P's or Moody's ratings.
- With discriminant analysis models, for four categories of ratings, 58% is the rate of correct forecasts, and drops to 36.3% when ratings are joined in six classes.

In case of neural networks, these proportions of correct forecasts jump to 69.7% and 51.9%.

- When the forecasts are related to the full set of 20 levels of rating, discriminant analysis produces 23.5% correct forecasts for S&P's, and 25.8% for Moody's, while the neural networks increase these figures to 31.4% and 32.3% (always with data not used in estimating the model. If the forecasts allow a difference of up to two notches, 79.1% and 85.3% are corrects forecasts.

Until 1970, the investor-pays or subscription-based business model was the norm. In addition, the demand for ratings remained stable; this system was in itself a guaranty of objectivity, but, was not sustainable.

Then, rating expanded due to several circumstances, such as the expansion of funds institutionalizing investments, the disintermediation at the margin of the financial firms, and the globalization process, in the present century. Fees are usually paid by the issuers or by the firms rated, and issuers where eager to show to potential investors their soundness.

This state of affairs tend to lower the issuer's firms financial costs. Obviously, possible conflict of interest became apparent, just contained by the willingness of Credit Rating Agencies in preserving their reputation.

VII. CONCLUSIONES

The appearance of Fitch, that is, the increase of competition in the Credit Rating Agencies environment, produced contradictory effects: rating inflation was clear, as one would expect, as in the issuer-pays' model, a firm has clear interest in obtaining higher grades, considering that this would lead to lower spread in its financing.

The quality of ratings is something that can only be evaluated in the future (today, with past statistical information about failures, the results can only be applied to what has already happened), and as these are 'opinions', what responsibility could be associated to the exercise of free speech? The possible regulation of Credit Rating Agencies is polemic.

The creation of public agencies is not very reassuring, as they would not risk even their reputation, in case of errors, and the civil servants appointed to these potential public agencies, would they respond to clear mistakes in their judgments?

The return to a pre-1970 issuer's pays model is not economically viable for the Credit Rating Agencies.

Not having a clear way to proceed to increase the quality of ratings, at least the information about the agencies results could be presented in a unified way, to promote studies about rating the raters, and these comparative studies could be made public by regulators, to create a clear incentive for maintaining a high reliability of rates.

When analyzing differences of ratings obtained by S&P's and Moody's, the first conclusion is that in more than half of the companies, the evaluation of both Credit Rating Agencies are coincident, but the differences test significantly, concluding that S&P's tend to assign better ratings than Moody's.

VII. CONCLUSIONES

With a contingency table to cross S&P's and Moody's ratings, two weighted measures about the differences of the ratings attributed to the same companies by the two agencies, are proposed. There are called displacement indices for each rating category and for each company, and they are summarized in two inflation indices.

The contributions to the market include not only evaluating the creditworthiness of firms, but also to define a common way of referring to credit risk of issues and firms, and, thus, to enable objective comparisons between them. These assessment functions have been provided, in the past, by different actors such as the financial press, credit reporting agencies, and bankers underwriting issues of securities.

The market of agencies is based on the three larger agencies, with important entry barriers. They compete between them for a limited number of issues and organizations, but not for improving the quality of ratings. In theory, when the markets conditions deteriorate, ratings for all of them should get lower. Nowadays, Moody's rating tend to be lower than S&P's, in ordinary times, in several sectors, while they are almost coincident for consumption and energy firms.

Comparing these results and their evolution between 2014 and 2018, the trend of both agencies is to converge in more similar ratings, which can be attributed to a better estimates of the default probabilities of the firms evaluated, or, more disturbingly, to an exchange of information between the agencies or, simply, that when a discrepancy is observed, the agencies tends to lower it.

In any case, a fact is that ratings are not predictive measures; they are based on past information; in most cases, incomplete.

But, they are managed and manipulated as they were predictive measures of the future health of companies and financial issues.

This is not the case.

7.2. FUTURE DEVELOPMENTS

1. The data base accumulated in both samples has not been fully analyzed, so our first aims will be to extend the results about rating forecasting to the full period available, that is 2010-2018. In a short time we expect to add data from 2019.

2. Also, we have similar data since 2004, so we expect to investigate the effect of the 2008 financial crisis upon the ratings, and to test the different models proposed during this period.

3. Regarding the financial ratios used as a predictor of the ratings, we intend to extend their range to several additional ratios, such as the cash ratio, the gross margin ratio, the return on equity ratio and some market value ratios such as the price-earning ratio, to test their possibilities.

4. We expect to use some additional statistical methods, such as Support Vector Machines, as a possible good alternative to Neural Networks, to forecast ratings.

5. Also, in some economic sectors, such as industry and retailing, there are enough data to investigate the possibility of setting up more precise forecasting models for corporate ratings. Also, using data from BankScope, it could be applied to the banking sector.

6. In the rating inflation aspect in different agencies, the lags found in several economic sectors between S&P's and Moody's, is an indicator that it is possible to obtain information about this phenomenon. Also, we found some evidence, that the agencies try to mimic each other, overreacting to some shifts in the ratings; this process, could be interesting to follow, and we expect to relate this to external events.

REFERENCIAS

REFERENCIAS

- Alpaydin, E. (2018). *Machine Learning: the new AI*. The MIT Press.
- Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23, 4, 589-609.
- Altman, E. (ed.) (2010). *The Z-Metrics methodology for estimating Company Credit Ratings and Default Risk Probabilities*. Risk Metrics Group.
- Altman, E.; Iwanicz-Drozowska, M; Laitinen, E. y Suvas, A. (2017). Financial Distress Prediction in an international context: a review and empirical analysis of Altman's Z-Score model. *Journal of International Financial Management & Accounting*, 28, 2, 131-171.
- Altman, E. y Saunders, A. (1998). Credit risk measurement: developments over the last 20 years. *Journal of Banking and Finance*, 21, 1721-1742.
- Altman E. y Rijken H. (2004). How Rating Agencies Achieve Rating Stability, *Journal of Banking and Finance*, 28, 11, 2679-2714.
- Amdouni, W. y I. Soumaré (2014). An analysis of the determinants of S&P ratings assigned to Canadian firms: application of a multinomial logit. *Journal of Risk Management in Financial Institutions*, 7, 4, 353-369.
- Angelini, E., di Tollo, G. y Roli, A. (2008). Modeling Credit Risk for SMEs: evidence from the U.S. market. *The Quarterly Review of Economics and Finance* 48, 733–755.
- Australian Securities & Investments Commission (2018). *Surveillance of Credit Rating Agencies*. Report 566.
- Baltaev, A. y Chavdarov, I. (2014). *Predicting Corporate Defaults: Evaluating Moody's Credit Rating Institute*. M.Sc. thesis. Lund University. Sweden.
- Beatty, A., Gilette, J., Petacchi, R. y Weber, J. (2019). Do rating agencies benefit from providing higher ratings? Evidence from the consequences of municipal bond ratings recalibration. *Journal of Accounting Research*, 57, 2, 323-354.
- Becker, B. y Milbourn, T. (2009). *Reputation and competition: evidence from the credit rating industry*, Harvard Business School, Working Paper No. 09-051.

Becker, B. y Milbourn, T. (2011). How Did Increased Competition Affect Credit Ratings? *Journal of Financial Economics*, 101, 493-514.

Bessis, J. (2007). *Risk management in banking*. 3 ed. John Wiley & sons.

Bhoge, M. (2019). Using Artificial Neural Network for Credit Risk Management. *Oracle Data Science B*. <https://blogs.oracle.com/datascience/using-the-artificial-neural-network-for-credit-risk-management>

Bissoondoyal-Bheenick, E. y Treepongkaruna, S. (2011). An analysis of the determinants of bank ratings: Comparison across ratings agencies. *Australian Journal of Management*, 36, 3, 405-424.

Black, F. y Scholes, M. (1973). The Pricing of Options and Corporative Liabilities. *The Journal of Political Economy*, 81, 3, 637 -654.

Blaurock, U. (2007). Control and Responsibility of Credit Rating Agencies. *Electronic Journal of Comparative Law*, 11.3, December.

Bloomberg Professional Services (2018). *Data and Content*.

<https://www.bloomberg.com/professional/solution/data-and-content/>

Bluhm, C.L., Overbeck, Y.C. y Wagner, C. (2003). *An introduction to Credit Risk Modelling*. Champman&Hall. CRC.

Bolancé. C., Guillén, M. Padilla, B. y Alemar, E. (2015). *Estimación del riesgo mediante cópulas*. D.T. Universidad de Barcelona.

Boland, P. (2007). *Statistical and probabilistic methods in Actuarial Science*. Chapmand & Hall. London.

Bongaerts, D. (2014). *Alternatives for issuer-paid Credit Rating Agencies*. W.P. 1-45. ECB.

Bolancé, C., Guillén, M. y Padillas A. (2015). *Estimación del riesgo mediate ajuste de cópulas*. W.P. 2015/01. UB Riskcenter.

Bonsall, S. (2014). The Impact of Issuer-Pay on Corporate Bond Rating Properties: Evidence from Moody's and S&P's Initial Adoptions. *Journal of Accounting and Economics* 57, 89-109.

Bowe, M. y Larik, W. (2014). Split Ratings and Differences in Corporate Credit Rating Policy between Moody's and Standard & Poor's. *Financial Review*, 49, 4, 713-734.

Cardoso, V.S., A.L.S. Guimaraes, H.F. Macedo y J. C. Lima (2013) Assessing Corporate Risk: a PD model based on credit ratings. *ACRN Journal of Finance and Risk Perspectives*, 2, 1, Nov., 51-58

Caridad, D.; Hanclova, J.; Bousselmi, H.W., Caridad y López del Río, L. (2019). Corporate rating forecasting using Artificial Intelligence statistical techniques. *Investment Management and Financial Innovations*, 16(2), 295-312.

Caridad, J.M. (2018). *Métodos cuantitativos en Economía*. Ediciones DF.

Campos Espinoza, R. (2012). *Técnicas de sistemas automáticos de soporte vectorial en la réplica del rating crediticio*. ESADE. Tesis doctoral.

Chaveesuk, R., C. Srivaree-Ratana y A. Smith (1999). Alternative Neural Network Approaches to Corporate Bond Rating. *Journal of Engineering Valuation and Cost Analysis*, 2, 1-17.

Cheridito, P., Ery, J. y Wuthrich, M. (2020). Assessing asset-liability risk with Neural Networks. *Risks* 2020, 8, 16.

Crouchy, M., Galai, D. y Mark, R. (2000). *Risk Management*. McGraw Hill.

Deshpande, A. (2014). Comparing the Value at Risk Performance of the CreditRisk+ and its Enhancement: A large Deviations Approach. *Methodology and Computing in Applied Probability*, 16:1009-1023, 2014.

Devasena, L. (2014). Competency comparison between logistic classifier and partial decision tree classifier for credit risk prediction. *Operations Research and Applications*, 1, 1, 31-40.

Dima, A.M. y S. Vasilache (2016). Credit risk modeling for companies default prediction using Neural Networks. *Romanian Journal of Economic Forecasting* XIX (3), 127-143.

Doumpos, M., Niklis, D., Zopounidis, C. y Andriosopoulos, K. (2015). Combining Accounting Data and a Structural Model for Predicting Credit Ratings: Empirical Evidence from European Listed Firms. *Journal of Banking and Finance*, 50, 599-607.

Duda, R.O., Hart, P.E. y Stork, D.G. (2001). *Pattern classification*. John Wiley & sons.

Dutta, S. y Shekhar, S. (1988). Bond rating: A non-conservative application of neural networks. In *Proceedings of the IEEE Int. Conf. on Neural Networks* 443-450.

Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14, 179-211.

Elmer, P.D. y James, S. (2012). A fuzzy-neuro model for intelligent credit risk management. *Intelligent Information Management*, 4 (5), 251-260.

Engelmann, B., Hayden, E. y Tasche, D. (2003). Testing rating accuracy. *Risk*, 16, 82-86.

Engvall, J. (2015) *Credit Rating Methodology*. Thesis Copenhagen Business School. Denmark.

Escrig-Olmedo, E., Fernandez-Izquierdo, M.A., Ferrero-Ferrero, I., Rivera-Lirio, J.M. y Muñoz-Torres, M.J. (2019). Rating the Raters: Evaluating how ESG Rating Agencies Integrate Sustainability Principles. *Sustainability*, 11, 3, 915.

European Commission, (2015). *Study on the Feasibility of Alternatives to Credit Ratings*. Directorate-General for Financial Stability, Financial Services and Capital Markets Union. Dec.

Fawcett, T. (2003). *ROC Graphs: Notes and Practical Considerations for Data Mining Researchers*, HP Laboratories Technical Report.

Figlewski, S., Frydman, H. y Liang W. (2012). Modeling the Effect of Macroeconomic Factors on Corporate Default and Credit Rating Transitions. *International Review of Economics and Finance*, 21, 87-105.

Fitch Ratings Inc. (2018). *Credit Ratings*. www.fitchsolutions.com/products/credit-ratings

Fitch Ratings Inc. (2018). Form 25-101F1, *Procedures and methodologies for determining Credit Ratings*. www.fitchratings.com/site

Fons, Jerome S. (1991) *An Approach to Forecasting Default Rates*. A Moody's Special Report, August, 1991.

Frank, S. J. (2018). *Predicting corporate credit ratings using neural network models*. Research Report. University of Stellenbosch.

Frydman, H. y Schuermann, T. (2008). Credit Rating Dynamics and Markov Mixture Models. *Journal of Banking and Finance*, 32, 1062-1075.

Gangolf, C., Dochow, R., Schmidt, G. y Tamisier, T. (2016). Automated credit rating prediction in a competitive framework. *RAIRO-Operations Research* 50, 749-765.

Garavaglia, S. (1991). *An application of a Counter-Propagation Neural Networks: Simulating the Standard & Poor's Corporate 556* Proceedings of the First International Conference on Artificial Intelligence on Wall Street, 278– 287.

García Céspedes, J.C. (2001). *Correlaciones en finanzas*. Seminario de Matemática Financiera. Instituto MEFF-UAM.

Giacomini, E. (2005). *Risk management with copulae*. Centre for Applied Statistics and Econometrics. Berlin Humboldt. University.

Gillette, J., Samuels, D. y Zhou, F. (2019) The effect of credit ratings on disclosure: evidence from the recalibration of Moody's municipal ratings. *Psychology*, https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3153143.

Gogas, P., Papadimitriou, T. y Agravetidou, A. (2013). *Forecasting bank credit ratings*. WP60.13. The Rimini Centre for Economic Analysis.

Goh, R.Y. y Lee, L.S. (2019). Credit Scoring: a reviews on Support Vector Machines and Metaheuristic Approaches. *Advances in Operations Research*, 2, 1-30.

Ghosh, S. (2013). *A Study of Differences in Standard & Poor's and Moody's Corporate Credit Ratings*, 1-14. www.stern.nyu.edu/sites/default/assets/documents/con_041250.pdf

Gray, S., Mirkovic, A. y Ragunathan, V. (2006). The determinants of credit ratings: Australian evidence. *Australian Journal of Management*, 31, 2, 333-354.

Hemraj, M. (2015). *Credit Rating Agencies. Self-regulation, Statutory Regulation and Case Law Regulation in the United States and European Union*. Springer.

Hopfield, J.J., y Tank, D.W. (1985). Neural computation of decisions in optimization problems. *Biological Cybernetics*, 52, 141–152.

Horrigan, J. (1966). Determination of long-term credit standing with financial ratios. *Journal of Accounting Research*, 4, 44-62.

Huang, Shian-Chang (2011). Using Gaussian Process Based Kernel Classifiers for Credit Rating Forecasting. *Expert Systems with Applications*, 38, 8607-8611.

Huang, Z.; Chen, C.; Hsu, Chen, W. y Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: a market comparative study. *Decision Support Systems*. 37, 543-558.

Irmatova, E. (2017). RELARM: a rating model based on relative PCA attributes and k-means clustering. *Russian Journal of Entrepreneurship*, 10, 1-20.

Jayadev, M. (2006). Predictive power of Financial Risks Factors: an empirical analysis of default companies. *Vikalpa*, 31, 3, 45-56.

Jonsson, J. G. y Fridson, M. S. (1996). Forecasting Default Rates on High Yield Bonds. *The Journal of Fixed Income*, 6, (1), 69-77.

Jordan, M. I. (1986). *Attractor dynamics and parallelism in a connectionist sequential machine*. Proceedings of the Eight Annual Conference of the Cognitive Science Society, 531-546, Erlbaum.

Kachalov, R., Sleptsova, Y. y Shokin, Y. (2018). *Application of Artificial Neural Network in Risk Management*. Management International Conference. MIC 2018. Bled. Slovenia.

Kamstra, M., Kennedy, P. y Suan, T. K. (2001). Combining Bond Rating Forecasts using Logit. *The Financial Review*, 37, 75-96.

Kaplan, S., y G. Urwitz (1979). Statistical Models of Bond Ratings: a methodological inquiry. *The Journal of Business*, 52, 2, 231-261.

Karminsky, A. y E. Khromova (2016). Extended modeling of banks' credit ratings. *Procedia Computer Science*, 91, 201-210.

Kee, K. (2005). Predicting bond ratings using publicly available information. *Expert Systems with Applications*, 29, 75-81.

Keenan, S. C., Sobehart, J. and Hamilton, D. T. (1999) *Predicting Default Rates: A Forecasting model for Moody's Issuer-based Default rates*. Moody's Investors Service.

Khemakhem, S. y Boujelbène, Y. (2015). Credit risk prediction: A comparative study between discriminant analysis and the neural network approach. *Accounting and Management Information Systems*, 14, 1, 60-78.

Khemakhem, S. Ben Said, F. y Boujelbène, Y. (2018). Credit risk assessment for unbalanced datasets based on data mining, artificial neural network and support vector machines, *Journal of Modelling in Management*, 13, 4, 932-951.

Kim, K.J. y Ahn, H. (2012). A corporate credit rating model using multi-class support vector machines with an ordinal pairwise partitioning approach. *Computers & Operations Research* 39(8): 1800-1811.

KMVCorporation (1993). *CreditMonitorOverview*, SanFrancisco, USA.

Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, 59-69.

Kohonen, T.; Hynninen, J.; Kangas, J. y Laaksonen, J.T. (1996a). *SOM_PAK: the self-organizing map program package*. Espoo: Helsinki University of Technology, Laboratory of Computer and Information Science. (Technical Report A31).

Kohonen, T.; Hynninen, J.; Kangas, J. y Laaksonen, J.T. (1996b). *LVQ_PAK: the learning vector quantization program package*. Espoo: Helsinki University of Technology, Laboratory of Computer and Information Science. (Technical Report A30).

Kramer, W. y Guettler, A. (2008). On comparing the accuracy of default predictions in the rating industry. *Empirical Economics*, 34, 2, 343-356.

- Kriz, K.A. y Xiao, Y. (2017). The impact of rating recalibration on municipal bond yield spreads: rating recalibration and yield spreads. *Public Budgeting & Finance*, 37, 2, 83-101.
- Kruse, R.; Borgelt, C.; Klawonn, F.; Moewes, C.; Steinbrecher, M. y Held, P. (2016). *Computational Intelligence: A Methodological Introduction* Springer.
- Kumar, K. y Haynes, J.D. (2003). Forecasting credit ratings using an ANN and Statistical Techniques. *International Journal of Business Studies*, 11, (1), 91-108.
- Kwon, J.; Choi, K. y Suh, Y. (2013). Double ensemble approaches to predicting firms' credit rating. *Conference Proceedings. PACIS*.
- Langohr, H., y Langhor, P. (2011). *The rating agencies and their credit ratings, what they are, how they work and why they are relevant*, John Wiley & Sons, Chichester, England.
- Laplante, A. y Rubtsov, A. (2019). Artificial Neural Networks in Financial Modelling. Global Risk Institute.
- Lara Haro, A. de (2006). *Medición y control de riesgos financieros*. Limusa. México.
- Lee M., y Lin, S. (2014). Integrating Genetic Algorithm and Rough Set Theory for Credit Rating Forecasting. *Research and Development* 46-47 (3) 177-184.
- Ligeti, I. y Szörfi, Z. (2016). Methodological issues of credit rating - Are sovereign credit rating actions reconstructible? *Financial and Economic Review*, 15, 1, 7-32.
- Livingston, M., Wei, J. y Zhou, L. (2010). Moody's and S&P Ratings: Are They Equivalent? Conservative Ratings and Split Rated Bond Yields. *Journal of Money, Credit and Banking*, 42, 7, 1267-1293.
- Losada López, R. (2009). Agencias de *rating*: hacia una nueva regulación. Comisión Nacional del Mercado de Valores. ISBN 978-84-87870-87-3.
- Macdonald, B.I.; Wilkins, M. y Zhuang, M. (2014). Lessons learned from 20 years of rating global project finance debt. Standard & Poor's Rating Services. Mc Graw Hill Financial. www.standardandpoors.com/ratingdirect.
- Maher, J. y Sen, T.K. (1997). Predicting Bond Ratings Using Neural Networks: A comparison with logistic regression. *Intelligent Systems in Accounting Finance & Management*, 6(1):59-72.
- Mandic, D., y Chambers, J. (2001). Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures, and Stability. New York: John Wiley and Sons.
- Mathis, J., McAndrews, J. y Rochet, J. (2009). Rating the Raters: Are Reputation Concerns Powerful Enough to Discipline Rating Agencies? *Journal of Monetary Economics*, 56, 657-674.

Mayer, M., F. Resch y S. Sauer (2017). Validating point-in-time vs. through-the-cycle credit rating systems. *Preliminary paper*.

Maher, J. y Sen, T.K. (1997). Predicting Bond Ratings Using Neural Networks: A Comparison with Logistic Regression. *Intelligent Systems in Accounting Finance & Management* 6(1):59-72.

Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7 (1), 77-91.

McCulloch, W.S. y W. Pitts. (1943). A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:115–133.

McLean, B. y Nocera, J. (2010). All the devils are here. The hidden history of the Financial Crisis. Portfolio Penguin Press.

Mehr, R. y Hedges, R. (2012). *Risk Management in the Business Enterprise*. Ergodebooks.

Merton, R.C. (1974). On the pricing of Corporate Debt: the risk structure of interest rates. *The Journal of Finance*, 29, 2, 449-470.

Metz, A. (2006). Moody's Credit Rating Prediction Model. Moody's Investors Service *Global Credit Research Report no. 100722*, 1-20.

Minescu, A.M. (2010). *Rating Agencies – General Issues and Potential Solutions*

Petroleum-Gas University of Ploiesti Bulletin, Economic Sciences Series LXII 2, 110-115.

Mirjalili, S., Faris, H. y Aljarah, I. (2019). *Evolutionary Machine Learning Techniques*. Springer.

Moody's Investors Service (2000). *KMV model*. Global Credit Research.

Moody's Investors Service (2002). *RiskCalc for private companies: Moody's default model*. Global Credit Research.

Moody's Investors Service (2017). *Moody's Financial Metrics Key Ratios by Rating and Industry for Global Non-Financial Corporates*. Data Report, 25 Sept.

Moody's Investors Service (2018) *Annual Default Study: Corporate Default and Recovery Rates*. 1920 - 2017. Data Report, 15 Feb.

Moody's Investors Service (2018) *Model for Moody's Issuer-Based Default Rates, A Special Report*.

Moosa, Imad A. (2017). The regulation of credit rating agencies: A realistic view. *Journal of Banking Regulation*, 18, 2, 180-220.

Mushang, L. y Sin-Jin, L. (2014). Integrating Genetic Algorithm and Rough Set Theory for Credit Rating Forecasting. *Research and Development*, 46-47 (3) 177-184.

Nehrebecka, N. (2018). Predicting the default risk of companies. Comparison of credit scoring models: Logit vs Support Vector Machines. *Advances in Applied Data Analysis*, 22, 2, 54-73.

Novales, A. (2017). *Cóputas*. Dpt. De Economía Cuantitativa. UCM.

Novotna, M. (2012). The use of different approaches for credit rating prediction and their comparison. 6th *Int. Sc. Conf. Managing and Modeling of Financial Risks* VSB-TU Ostrava 448-457.

Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18, 1, 109-131.

Ong, M.K. (2002). *Credit ratings - Methodologies, rationale and default risk*, Risk Books, London, 213-231.

Petropoulos, A., Chatzis, S. y Xanthopoulos, S. (2016). A Novel Corporate Credit Rating System Based on Student's-t Hidden Markov Models. *Expert Systems with Applications*, 53, 87-105.

Pichereau, L. (2016). Empirical study of credit rating agencies: do the financial characteristics of companies have an impact on the occurrence of split ratings? Thesis. file:///C:/Users/jmeca/AppData/Local/Temp/Thesis_LaurencePichereau_s111186.pdf

Pinches, G.E. y Mingo, K.A. (1973). A Multivariate Analysis of Industrial Bond Ratings. *Journal of Finance*, 28, 1, 1-18.

Ptak-Chmielewska, A. (2016). Statistical models for corporate credit risk assessment-rating models. *Acta Universitatis Lodzianis Folia Oeconomica* 3, (322), 87-111.

Ravshanbek ogli Zokirjonov, M. (2017). Methodology of creditmetrics for credit risk assessment. *International Finance and Accounting*, 3, June, 1-9.

Resti, A. (2002) *Replicating agency ratings through multivariate scoring models in Ong*, MK.

Resti A. y Sironi, A. (2007). *Risk Management and Shareholders' Value in Banking*. Wiley.

RiskMetrics Group (2007). *CreditMetrics-Technical document*.

[//www.msci.com/documents/10199/93396227-d449-4229-9143-24a94dab122f](http://www.msci.com/documents/10199/93396227-d449-4229-9143-24a94dab122f)

Rovira, X., Ansotegui, C., Campos, R. y Sánchez, G. (2005). Predicción del Rating: Métodos Estadísticos Clásicos vs. Máquinas de Soporte Vectorial. *Ponencia en Workshop sobre Inteligencia Computacional*, CAEPIA 2005, Santiago de Compostela.

Roy, A.G. y Urolagin, S. (2019). *Credit Risk Assessment using Decision Tree and Support Vector Machine based data analytics*. Springer.

Rumelhart, D. E. y McClelland, J. (1986). *Parallel Distributed Processing*. MIT Press, Cambridge.

Sabatino, M. (2014). The Business Model of Rating Agencies between Asymmetric Information and Financial Crises. *Journal of Economics and Development Studies*, Dec., 2, 4, 165-183.

Saha, S. y Waheed, S. (2017). Credit risk of bank customers can be predicted from customer's attribute using Neural Networks. *International Journal of Computer Applications*, 161 (3), 39-43.

Sharpe, W.F. (1964). Capital asset prices: a theory of market equilibrium under conditions of risk. *The Journal of Finance*, 19, 3, 425-442.

Shin, K.S.; Lee, T.S. y Kim, H. (2005). An application of Support Vector Machines in bankruptcy prediction model. *Expert Systems with Applications*, 28, 127-135.

Schmid, B. (2012). *Credit Risk Pricing Models: Theory and Practice*. Springer.

Smith, M. (1993). *Neural Networks for Statistical Modeling*, Van Nostrand Reinhold.

The Financial Crisis Inquiry Commission (2011). *The Financial Crisis Inquiry Report*. Official Government Edition. US Government Printing Office.

Taleb, N.N. (2010). *The black swan: the impact of the hhighly improbable*. 2 ed. Random House Inc. N.Y.

The Public Risk Management Association (2010). *A structured approach to Enterprise Risk Management and the requirements of ISO 31000*. AIRMIC, alarm, IRM.

Tzu-Tsung, W. y Shang-Jung, Y. (2019). Weighted Random Forest for Evaluating Financial Credit Risk. *Proceedings of Engineering and Technology Innovation*, 13, 1-9.

Standard & Poor's Rating Services (2010) *Guide to Credit Rating Essentials*. 1-20.

Standard & Poor's Rating Services (2014). *Standard & Poor's Rating definitions*. Nov. 20.

Surkan, A. y Singleton, J.C. (1990). Neural networks for bond rating improved by multiple hidden layers. *IJCNN International Joint Conference on Neural Networks*, 2, 157-162.

Theil, H., (1967). *Economics and Information Theory*, North-Holland, Amsterdam

Tsai, C.F. y J.W. Wu (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 34, 2639-2649.

Viegas de Carvalho, P., Laux, P. A. y Pereira, J. P. (2014). The Stability and Accuracy of Credit Ratings. *SSRN Electronic Journal*. <https://ssrn.com/abstract=250497>

Widrow, B. y M. E. Hoff (1960). *Adaptive switching circuits*. 1960 IRE Wescon Convention Record. New York IRE, pages 96–104, 1960.

White L. J. (2018). *The Credit Rating Agencies and their role in the Financial System*. En E. Brousseau, ed., *Oxford Handbook on Institutions, International Economic Governance, and Market Regulation*, Oxford University Press.

Xia, H. (2014). Can Investor-Paid Credit Rating Agencies Improve the Information Quality of Issuer-Paid Rating Agencies? *Journal of Financial Economics*, 111, 2, 450-468.

Xing, H., Sun, N. y Chen, Y. (2012). Credit Rating Dynamics in the Presence of Unknown Structural Breaks. *Journal of Banking and Finance*, 36, 78-89.

Yakymova, L. y Kuz, V. (2019). The use of discriminant analysis in the assessment of municipal company's financial health. *Economics & Sociology*, 12, 2, 64-78.

Yeh, Ching-Chiang; Lin Fengyi y Hsu, Chih-Yu (2012). A Hybrid KMV Model, Random Forests and Rough Set Theory Approach for Credit Rating. *Knowledge-Based Systems*, 33, 166-172.

Zhao, Z., Xu, S., Ho Kang, B., Jahangir, M.M., Kabir Y, Liu y Wasinger, R. (2015). Investigation and improvement of multi-layer perceptron neural networks for credit scoring. *Expert Systems with Applications*, 42, 3508–3516.